

# 日本国特許庁 JAPAN PATENT OFFICE

別紙添付の書類に記載されている事項は下記の出願書類に記載されている事項と同一であることを証明する。

This is to certify that the annexed is a true copy of the following application as filed with this Office

出願年月日

Date of Application:

2001年11月 9日

出 願 番 号

Application Number:

特願2001-344010

[ ST.10/C ]:

[JP2001-344010]

出 顏 人
Applicant(s):


株式会社日立製作所

USSN 10/082,303 Mattingly Stanger Malur 703 684-1120 DAT ASA-1068

# CERTIFIED COPY OF PRIORITY DOCUMENT

2002年 2月15日

特許庁長官 Commissioner, Japan Patent Office 及川耕



【書類名】

特許願

【整理番号】

K01010341A

【あて先】

特許庁長官

【国際特許分類】

G06F 3/06

【発明者】

【住所又は居所】

神奈川県川崎市麻生区王禅寺1099番地 株式会社日

立製作所 システム開発研究所内

【氏名】

本田 聖志

【発明者】

【住所又は居所】

神奈川県小田原市国府津2880番地 株式会社日立製

作所 ストレージ事業部内

【氏名】

高安 厚志

【発明者】

【住所又は居所】

神奈川県小田原市国府津2880番地 株式会社日立製

作所 ストレージ事業部内

【氏名】

齊木 栄作

【特許出願人】

【識別番号】

000005108

【氏名又は名称】

株式会社日立製作所

【代理人】

【識別番号】

100075096

【弁理士】

【氏名又は名称】

作田 康夫

【先の出願に基づく優先権主張】

【出願番号】

特願2001-153345

【出願日】

平成13年 5月23日

【手数料の表示】

【予納台帳番号】

013088

【納付金額】

21,000円

## 特2001-344010

## 【提出物件の目録】

【物件名】

明細書 1

【物件名】

図面 1

【物件名】

要約書 1

【包括委任状番号】

9902691

【プルーフの要否】

要

## 【書類名】 明細書

【発明の名称】 記憶装置システム

【特許請求の範囲】

## 【請求項1】

上位装置と接続された複数の記憶装置からなる記憶装置システムにおいて、

前記複数の記憶装置に含まれる第1の記憶装置が、

前記上位装置における前記記憶システムに対する情報処理についての要求を受信する手段と、

受信された前記要求を、前記複数の記憶装置に含まれる第2の記憶装置に転送可能な手段と、

受信された前記要求が、当該第1の記憶装置が実行すべき要求である場合に、 受信された前記要求が示す情報処理を実行する手段とを有することを特徴とする 記憶装置システム。

## 【請求項2】

請求項1に記載の記憶装置システムにおいて、

前記情報処理を実行する手段は、当該第1の記憶装置が実行すべき要求を示す 協調制御情報と受信された前記要求に基づいて、受信された前記要求を実行すべ きと判断された場合に、前記情報処理を実行することを特徴とする記憶装置シス テム。

## 【請求項3】

請求項2に記載の記憶装置システムにおいて、

前記要求には、前記情報処理を実行すべき記憶装置を示す第1の識別情報が含まれ、前記強調制御情報には、当該第1の記憶装置を識別する第2の識別情報が含まれ、

前記情報処理を実行する手段は、前記第1の識別情報と前記第2の識別情報が 対応する場合に、前記情報処理を実行することを特徴とする記憶装置システム。

#### 【請求項4】

請求項1乃至3のいずれかに記載の記憶装置システムにおいて、

前記第2の記憶装置が、

前記転送される要求を受信する手段と、

転送された前記要求が、当該第2の記憶装置で実行すべき要求である場合に、 転送された前記要求が示す情報処理を実行する手段とを有することを特徴とする 記憶装置システム。

#### 【請求項5】

請求項4に記載の記憶装置システムにおいて、

前記第1の記憶装置では、転送可能な手段が、転送する要求に当該第1の記憶 装置を示す情報を付加し、

前記第2の記憶装置は、付加された前記第1の記憶装置を示す情報に基づいて、転送された前記要求の再度の転送を抑止する手段を、さらに有することを特徴とする記憶装置システム。

## 【請求項6】

請求項1に記載の記憶装置システムにおいて、

前記転送可能な手段は、当該第1の記憶装置が実行すべき要求を示す協調制御情報と受信された前記要求に基づいて、受信された前記要求を実行すべきでない と判断された場合に、受信された前記要求を、前記第2の記憶装置に転送することを特徴とする記憶装置システム。

#### 【請求項7】

請求項1または6のいずれかに記載の記憶装置システムにおいて、

前記転送可能な手段は、当該第1の記憶装置が実行すべき要求を示す協調制御情報と受信された前記要求に基づいて、受信された前記要求を前記第2の記憶装置が実行すべきと判断された場合に、受信された前記要求を、前記第2の記憶装置に転送することを特徴とする記憶装置システム。

#### 【請求項8】

請求項7に記載の記憶装置システムにおいて、

前記要求には、前記情報処理を実行すべき記憶装置を示す第1の識別情報が含まれ、前記強調制御情報には、当該第1の記憶装置を識別する第2の識別情報が含まれ、

前記情報処理を実行する手段は、前記第1の識別情報と前記第2の識別情報が

対応する場合に、前記情報処理を実行することを特徴とする記憶装置システム。

## 【請求項9】

請求項1および6乃至8のいずれかに記載の記憶装置システムにおいて、

前記第2の記憶装置が、

前記転送される要求を受信する手段と、

転送された前記要求が、当該第2の記憶装置で実行すべき要求である場合に、 転送された前記要求が示す情報処理を実行する手段とを有することを特徴とする 記憶装置システム。

## 【請求項10】

請求項9に記載の記憶装置システムにおいて、

前記第1の記憶装置では、転送可能な手段が、転送する要求に当該第1の記憶 装置を示す情報を付加し、

前記第2の記憶装置は、付加された前記第1の記憶装置を示す情報に基づいて、転送された前記要求の再度の転送を抑止する手段を、さらに有することを特徴とする記憶装置システム。

## 【請求項11】

請求項1乃至10のいずれかに記載の記憶装置システムにおいて、

前記要求は、前記複数の記憶装置のいずれかに記憶された情報に対する読み出し要求および前記複数の記憶装置のいずれかへの情報の書き込み要求のうち少なくとも一方が含まれることを特徴とする記憶装置システム。

#### 【発明の詳細な説明】

[0001]

#### 【発明の属する技術分野】

本発明は、データを二重化し保持する記憶装置システムに係る。特に、当該記憶装置システムを構成する複数の記憶装置間での協調制御に関する。

[0002]

## 【従来の技術】

"A Case for Redundant Array of Inexpensive Disks (RAID)" (Proceedings of ACM SIGMOD, 1988)には、複数のディスク装置から構成されるディスクアレ

イ装置における、冗長データの生成、及び格納方法による分類が規定されている

[0003]

上記の技術によれば、二台のディスク装置に対して二重化したデータを格納することで、冗長構成を取る一台のディスク装置において障害が発生し、当該ディスク装置の格納データの読出し、或いは、当該ディスク装置に対する書込みが不可能になった場合でも、他のディスク装置を用いてデータの読出し、書込みを可能とするディスクアレイ装置は、RAID1と呼んでいる。

[0004]

更に、上記RAID1のディスクアレイ装置において、ディスクアレイ装置内のディスク制御装置から二重化したディスク装置に対するライトデータの転送処理を軽減することで、ディスク制御装置の処理性能を向上させる技術が、特開平10-74129(第一の従来技術)に開示されている。

[0005]

第一の従来技術によれば、データライトの際、ディスク制御装置は、第一のディスク装置にのみライトデータを転送し、該ライトデータを第一のディスク装置が、ディスク制御装置を経由せず、第二のディスク装置に転送することによって、ディスク制御装置から第二のディスク装置に対するライトデータの転送処理を不要とすることが可能となる。

[0006]

更に、二台のディスク装置間を専用の連絡線で相互に結合し、データライトの際、相互に連絡を取りながら同時にライト処理を実施する方法が、特開平7-2819 59 (第二の従来技術) に開示されている。

[0007]

第二の従来技術によれば、二台のディスク装置に対し同時にライトデータの転送を実施することによって、インタフェース上のライトデータの転送量は、二重化しない場合と同等で実現することが可能となる。

[0008]

【発明が解決しようとする課題】

上述の第一の従来技術においては、少なくとも、ディスクアレイ装置を構成する個々のディスク装置を制御し、第一のディスク装置に対して特殊なライトコマンドを発行する手段を持つディスク制御装置を必要とする為、ディスクアレイ装置が高価になるという課題がある。

## [0009]

更に、上記従来技術においては、インタフェース上のライトデータの転送量を 低減するものではなく、即ち、ディスク制御装置とディスク装置とを接続するイ ンタフェース負荷を軽減するものではない為、ディスクアレイ装置内のインタフ ェースの競合による性能低下を改善することができないという課題がある。

## [0010]

また、第二の従来技術においては、第一の従来技術で課題とされた、ディスク 制御装置を不要とし、更に、インタフェース上のライトデータの転送量増加を防 止するものであるが、その実現において、ディスク装置間で連絡をとりあう為の 専用の連絡線が必要となる。

## [0011]

更に、二台のディスク装置で同期して、或いは、主側装置が副側装置の動作の 進行を確かめながら、ライトデータの転送処理を実現する為、ディスク装置の利 用効率の低下による性能低下、或いは、一台のディスク装置のデータライト処理 に対し余分に処理時間が掛かることによる性能低下という課題がある。

## [0012]

また、上述の従来技術においては、第一/第二、或いは、主側/副側の切り替え制御方法について、更に、データリード処理時のディスク装置選択制御方法について、充分考慮されているとは言えない。

#### [0013]

本発明の目的は、複数の記憶装置から構成されるRAID1の記憶装置システムにおいて、上位装置からのデータリード/ライト要求を、該記憶装置システムを構成する複数の記憶装置間で協調して処理する制御方式を提供することにある。このことにより、上述の課題を解決する記憶装置システムを提供することである。

## [0014]

また、本発明は、RAID1以外のRAIDシステムにも適用可能である。

[0015]

## 【課題を解決するための手段】

上記目的を達成するために、複数の記憶装置から構成されるRAID1を含む記憶装置システムにおいて、以下の構成をとる。

[0016]

本発明では、記憶装置システムに含まれる記憶装置が、上位装置における記憶装置システムに対する情報処理についての要求を受信する手段と、受信された要求を、複数の記憶装置に含まれる第2の記憶装置に転送可能な手段と、受信された要求が、当該第1の記憶装置が実行すべき要求である場合に、受信された要求が示す情報処理を実行する手段とを有するものである。

## [0017]

また、記憶装置システムを構成する個々の記憶装置が、少なくとも上位装置から記憶装置システムに対するライトデータ要求を共有する手段と、上記共有したライトデータ要求について、対を成す記憶装置との間でライトデータの転送処理と、当該ライトデータ要求に対するステータス情報の送信処理とを同期して実施する手段とを具備する構成であってもよい。

[0018]

## 【発明の実施の形態】

以下、本発明に係る第1の実施の形態を、図を用いて説明する。

図1は、二台の記憶装置1-a/bから構成される記憶装置システム4と、複数の上位装置2とが、任意のインタフェース(図中、SAN: Storage Area Network) 3で接続される、情報処理システムの一構成例を示す図である。

[0019]

同図において、記憶装置1としてディスク装置を例に構成を示しており、該ディスク装置1-a/bは、夫々前記上位装置2がアクセスするデータを保持する記憶媒体であるディスク部11と、該ディスク部11と前記上位装置2との間で転送されるデータを一時保持するバッファ部12と、前記上位装置2との間のインタフェースプロトコル制御を実行するインタフェース制御部13と、前記ディスク

部11に対する記録再生処理を実行するディスク制御部14と、前記バッファ部 12に対するアクセスを制御するバッファ制御部15と、上記各部位を統括制御 するメイン制御部10とから構成されている。

[0020]

また、同図において、前記ディスク装置 1-a/bが二重化されたデータを保持することによって、前記RAID1の記憶装置システムを構成するものである。

[0021]

尚、同図において、該記憶装置システムを二台のディスク装置から構成する場合を例としているが、本発明の記憶装置システムの構成は、これに限るものではなく、3台以上の記憶装置が含まれてもよい。

[0022]

以下、本発明に係る第一の実施形態を、図2、3、4、5、6、7、8を用いて説明する。本実施形態は、各記憶装置が要求を有し(もしくは受信し)、各記憶装置が当該記憶装置でその要求に対応する情報処理を実行すべきか判断する。 判断には、協調制御情報28を用いる。

[0023]

本実施形態では、上位装置2から記憶装置システム4に対するアクセス要求を、該記憶装置システム4を構成する複数の記憶装置1で共有し、更に、個々の記憶装置において、前記アクセス要求を自身が処理すべきか否かを判別することによって、個々の記憶装置を制御する制御装置が不要で低価格な、また、最適な記憶装置の利用効率が期待される高性能な前記記憶装置システムを実現することを可能にする。

[0024]

図2は、前記記憶装置システム4を構成するディスク装置1の一構成例を示す図である。

同図において、前記インタフェース制御部13は、前記インタフェース3を介して情報の受信を実施する受信部20と、同様に情報の送信を実施する送信部21と、受信したフレーム等の情報に対するエラー検出、或いは、該フレーム情報の少なくとも一部を前記バッファ部12に格納する際、格納先の制御等を実施す

る受信フレーム処理部 2 2 と、フレーム等の情報送信の際、該フレーム情報を構成するヘッダ情報等の付加情報の生成を実施する送信フレーム生成部 2 3 とを具備する。

## [0025]

更に、前記受信部20で受信したフレーム等の情報を後段の装置に対し再送するか否かを判別し、再送制御信号を生成する再送判定部24と、上記再送制御信号に基づき、前記送信フレーム生成部23からの情報と、前記受信部20で受信した情報との一方を選択し、前記送信部21に出力する出力選択部25とを具備する。

#### [0026]

また、前記バッファ部12は、上位装置2から受信したアクセス要求(コマンド)を保持する受信コマンド格納部26と、上位装置2との間で送受信されるデータを保持する送受信データ格納部27とを具備する。

## [0027]

また、前記メイン制御部10では、上位装置2から記憶装置システム4に対するアクセス要求について、該アクセス要求を後段の装置に再送するか否か、更には、該アクセス要求を自身が処理すべきか否かを判別する為の情報等、対を成すディスク装置との間での協調制御情報28を保持している。なお、協調制御情報28の詳細に関しては、図16を用いて後述する。

## [0028]

更にまた、前記再送判定部24では、上位装置2から記憶装置システム4に対するフレーム等の情報の再送制御として、アクセス要求については、前記協調制御情報28に基づく再送制御を、ライトデータについては、該ライトデータのフレームを構成するヘッダ情報等に基づく再送(転送)制御を実施するものである

#### [0029]

以下、上位装置から記憶装置システムに対するアクセス要求について、アクセス要求領域を条件として、該アクセス要求を自身が処理すべきか否かを個々のディスク装置で判別する場合のリード/ライトデータ転送処理を例に動作を説明す

る。

[0030]

図3は、前記ディスク装置1-a/bから構成される記憶装置システム4に対し、 上位装置2からのリードデータ要求が発行された場合の、各装置における処理の 流れを示す図である。

[0031]

(1) アクセス要求(コマンド) 受信及び再送処理

上位装置2から記憶装置システム4に対して発行されたリードデータ要求は、フレーム情報として、先ず、ディスク装置1-aの前記受信部20を介して受信される。ディスク装置1-aでは、前記リードデータ要求を、前記受信フレーム処理部22を介して、前記バッファ部12の前記受信コマンド格納部26に格納する

[0032]

また、ディスク装置 1-aの前記再送判定部 2 4 は、前記協調制御情報 2 8 に基づき、上位装置 2 から記憶装置システム 4 に対するアクセス要求を後段のディスク装置 1-bに対して再送するように設定しておくことによって、受信したフレーム情報がアクセス要求であることを検出し、前記出力選択部 2 5 に対する再送制御(指示)信号を生成する。結果、前記出力選択部 2 5 は、上記再送制御(指示)信号に基づき、前記上位装置からのリードデータ要求を後段のディスク装置 1-bに対し再送する。

[0033]

ディスク装置 1-bでは、前記ディスク装置 1-aによって再送された前記リードデータ要求を、前記受信フレーム処理部 2 2 を介して、前記バッファ部 1 2 の前記受信コマンド格納部 2 6 に格納する。また、ディスク装置 1-bの前記再送判定部 2 4 は、前記協調制御情報 2 8 に基づき、アクセス要求を後段の装置に対し再送しないよう設定されている。

[0034]

(2)アクセス要求(コマンド)解釈及びアクセス要求(コマンド)実行 ディスク装置1-a/bは、前記受信コマンド格納部26に格納したアクセス要求 を解釈し、該アクセス要求がリードデータ要求であることを検出する。

[0035]

更に、該リードデータ要求を構成するリード要求領域情報と、前記協調制御情報28とに基づき、前記該リードデータ要求を自身が処理すべきか否かを判別する。

[0036]

自身が処理すると判断したディスク装置では、前記ディスク制御部14を介してディスク部11から前記バッファ部12の前記送受信データ格納部27に対するディスクリード処理を開始し、更に、前記インタフェース制御部13を介して上位装置2に対するリードデータ送信処理を実施する。更に、リードデータ送信後、前記リードデータ要求に対するステータス情報を生成送信し、前記アクセス要求を削除することによって、一連のリードデータ要求処理を完了する。

[0037]

一方、自身が処理しないと判断したディスク装置では、前記アクセス要求を削 除することによって、リードデータ要求に掛かる処理を完了する。

[0038]

なお、本実施形態では、アクセス要求が、ディスク装置1-aを介してディスク 装置1-bに転送されるが、ディスク装置それぞれに、上位装置2がアクセス要求 を送信してもよい。

[0039]

図4は、前記ディスク装置1-a/bから構成される記憶装置システム4に対し、上位装置2-a/bからのリードデータ要求が発行された場合、特に、上位装置2-aからのリードデータ要求がディスク装置1-aで、上位装置2-bからのリードデータ要求がディスク装置1-bで処理される場合の、リードデータ要求、及び、リードデータの転送処理等の流れを示す図である。

[0040]

上述の説明の通り、上位装置 2-a/bからのリードデータ要求は、少なくともディスク装置 1-aのインタフェース制御部 1 3 を介して、ディスク装置 1-a/bのバッファ部 1 2 に格納される。

## [0041]

ディスク装置 1-a/bでは、受信したアクセス要求について、自身が処理すべきか否かを判別し、自身が処理すると判断したリードデータ要求に対して、ディスク部 1 1 からのディスクリード処理、及び、上位装置 2-a/bに対するリードデータ送信処理、更に、ステータス生成送信処理を実施する。ここで、ディスク装置 1-aが送信するリードデータは、上位装置 2-aに対するものであることから、従来通りディスク装置1-bのインタフェース制御部 1 3 を介して上位装置 2-aに転送される。

## [0042]

図5は、前記ディスク装置1-a/bから構成される記憶装置システム4に対し、 上位装置2からのライトデータ要求が発行された場合の、各装置における処理の 流れを示す図である。

## [0043]

## (1)アクセス要求(コマンド) 受信及び再送処理

対象となるアクセス要求が、リードデータ要求でなくライトデータ要求であること以外は、図3を用いて上述した内容と同じである。上位装置2から記憶装置システム4に対して発行されたライトデータ要求は、フレーム情報として、先ず、ディスク装置1-aの前記受信部20を介して受信される。

## [0044]

ディスク装置1-aでは、前記ライトデータ要求を、前記受信フレーム処理部2 2を介して、前記バッファ部12の前記受信コマンド格納部26に格納する。

#### [0045]

また、ディスク装置1-aの前記再送判定部24は、前記協調制御情報28に基づいて、上位装置2から記憶装置システム4に対するアクセス要求を後段のディスク装置1-bに対して再送するように設定しておくことによって、受信したフレーム情報がアクセス要求であることを検出し、前記出力選択部25に対する再送制御(指示)信号を生成する。結果、前記出力選択部25は、該再送制御(指示)信号に基づき、前記上位装置からのライトデータ要求を後段のディスク装置1-bに対し再送する。

[0046]

ディスク装置 1-bでは、前記ディスク装置 1-aによって再送された前記ライトデータ要求を、前記受信フレーム処理部 2 2 を介して、前記バッファ部 1 2 の前記受信コマンド格納部 2 6 に格納する。また、ディスク装置 1-bの前記再送判定部 2 4 は、前記協調制御情報 2 8 に基づき、アクセス要求を後段の装置に対し再送しないよう設定されている。

[0047]

(2) アクセス要求 (コマンド) 解釈及びアクセス要求 (コマンド) 実行

対象となるアクセス要求が、リードデータ要求でなくライトデータ要求であること以外は、図3を用いて上述した内容と同じである。ディスク装置1-a/bは、前記受信コマンド格納部26に格納したアクセス要求を解釈し、該アクセス要求がライトデータ要求であることを検出する。更に、該ライトデータ要求を構成するライト要求領域情報と、前記協調制御情報28とに基づき、前記該ライトデータ要求を自身が処理すべきか否かを判別する。

[0048]

自身が処理すると判断したディスク装置では、前記バッファ部12の送受信データ格納部27を確保し、上位装置に対しライトデータの転送開始要求を送信する。

[0049]

更に、上記ライトデータの転送開始要求を受信した上位装置 2 から送信される ライトデータを、予め確保した送受信データ格納部 2 7 に格納する。更に、ライトデータ受信後、或いは、受信したライトデータを前記ディスク部 1 1 に対しライトするディスクライト処理完了後、前記ライトデータ要求に対するステータス 情報を生成送信し、前記アクセス要求を削除することによって、一連のライトデータ要求処理を完了する。

[0050]

一方、自身が処理しないと判断したディスク装置では、前記アクセス要求を構成するライト要求領域情報に基づき、後述の未更新領域管理情報を更新した後、 前記アクセス要求を削除することによって、ライトデータ要求処理を完了する。

## [0051]

図6は、前記ディスク装置1-a/bから構成される記憶装置システム4に対し、上位装置2-a/bからのライトデータ要求が発行された場合、特に、上位装置2-aからのライトデータ要求がディスク装置1-aで、上位装置2-bからのライトデータ要求がディスク装置1-bで処理される場合の、ライトデータの転送開始要求、及び、ライトデータの転送処理等の流れを示す図である。

## [0052]

上述の説明の通り、上位装置 2-a/bからのライトデータ要求は、少なくともディスク装置 1-aのインタフェース制御部 1 3 を介して、ディスク装置 1-a/bのバッファ部 1 2 に格納される。

#### [0053]

ディスク装置 1-a/bでは、受信したアクセス要求について、自身が処理すべき か否かを判別し、 自身が処理すると判断したライトデータ要求の要求元上位装 置に対して、ライトデータの転送開始要求を送信し、これを契機に上位装置から 送信が開始されるライトデータを、送受信データ格納部 2 7 に格納する。

更に、ライトデータ受信後、或いは、受信したライトデータを前記ディスク部 11に対しライトするディスクライト処理完了後、前記ライトデータ要求に対す るステータス情報の生成送信処理を実施する。

## [0054]

ここで、ディスク装置 1-aから上位装置 2-aに対して送信されるライトデータの転送開始要求、及び、ステータス情報は、前述のリードデータの転送処理と同様に、従来通りディスク装置1-bのインタフェース制御部 1 3 を介して上位装置 2-aに転送される。

## [0055]

また、上位装置 2-a/bから記憶装置システム 4 に対して送信されるライトデータについては、該ライトデータのフレームを構成するヘッダ情報等に基づく再送(転送)制御を、前記ディスク装置1-a/bのインタフェース制御部 1 3 の再送判定部 2 4 で実施する。即ち、上位装置 2-aからのライトデータについては、前記ディスク装置1-aのインタフェース制御部 1 3 の再送判定部 2 4 で、該ライトデ

ータのフレームを構成するヘッダ情報等に基づく再送(転送)判定制御の結果、 後段に転送されること無くディスク装置1-aのバッファ部12に格納される。

[0056]

また、上位装置 2-bからのライトデータについては、前記ディスク装置1-aのインタフェース制御部 1 3 の再送判定部 2 4 で、該ライトデータのフレームを構成するヘッダ情報等に基づく再送(転送)判定制御の結果、後段への転送が実施され、更に、前記ディスク装置1-bのインタフェース制御部 1 3 の再送判定部 2 4 で、該ライトデータのフレームを構成するヘッダ情報等に基づく再送(転送)判定制御の結果、後段に転送されること無くディスク装置 1-bのバッファ部 1 2 に格納される。

[0057]

上述の通り、本実施形態では、複数の記憶装置から構成される記憶装置システムにおいて、該記憶装置システムを構成する個々の記憶装置が、上位装置から記憶装置システムに対するアクセス要求を、前記複数の記憶装置で共有する手段と、共有したアクセス要求について、自身が処理すべきか否かを判別する手段と、更に、上位装置から記憶装置システムに送信されるライトデータを、少なくとも、処理すべきと判断した記憶装置に転送する手段とを具備することによって、個々の記憶装置を制御する制御装置が不要で低価格な、また、最適な記憶装置の利用効率が期待される高性能な記憶装置システムが実現可能となる。

[0058]

尚、本実施形態では、上位装置2からのライトデータ要求によって、一時的にディスク装置1-a/bに格納されたデータの不一致が生じてしまう。そこで、以下に本実施形態におけるライトデータの更新処理例を説明する。

[0059]

図7は、前述の上位装置からのライトデータ要求を自身が処理しないと判断したディスク装置において、更新処理が実施される未更新領域管理情報30の一構成例を示す図である。

[0060]

未更新領域管理情報30としては、少なくとも未更新領域に関する情報を持つ

ものであり、同図においては、上位装置から記憶装置システムに対するアクセス 要求が、アクセス開始アドレス情報と、アクセスサイズ情報とから構成される場 合を例に、未更新開始アドレス情報と、未更新サイズ情報とを持ち、更に、未更 新領域に関する更新時刻情報等の更新情報を含む構成としている。

## [0061]

上位装置からのライトデータ要求を受信し、自身が処理しないと判断したディスク装置では、ライトデータ要求を構成するライト要求領域情報に基づき、未更新領域管理情報30を更新することによって、不一致の発生した未更新領域の管理、及び、以降の未更新領域の更新処理を可能としている。

## [0062]

図8は、ディスク装置1-bの未更新領域管理情報30に基づき、不一致の発生 した未更新領域の更新処理を実施する場合の、更新要求、及び、更新データの転 送処理等の流れを示す図である。

同図において、ディスク装置1-bは、自身の未更新領域管理情報30に基づき、対を成すディスク装置1-aに対し、更新要求を発行する。該更新要求を受領したディスク装置1-aでは、必要ならばディスク部11からのディスクリードを実施し、要求対象のデータをディスク装置1-bに対し送信する。ディスク装置1-bでは、上記ディスク装置1-aから受信したデータをディスク部11に格納し、当該処理に掛かる未更新領域情報を未更新領域管理情報30から削除することによって、未更新領域の更新処理を完了する。

#### [0063]

尚、上述の実施形態において、上位装置からのライトデータ要求を受信し、自身が処理しないと判断したディスク装置が、不一致の発生した未更新領域の管理、及び、以降の未更新領域の更新処理を実施するものとしているが、これに限るものではなく、例えば、自身が処理すると判断したディスク装置が、ライトデータ要求を構成するライト要求領域情報に基づき、未更新領域管理情報30を更新することによって、不一致の発生した未更新領域の管理、及び、以降の未更新領域の更新処理を実施することも可能である。

[0064]

更に、未更新領域の更新処理を開始する契機は任意である。例えば、未更新領域管理情報30に登録されたエントリー数、或いは、総未更新領域サイズ等に基づき開始することが可能である。

[0065]

以下、本発明に係る第二の実施形態を、図9、10、11、12、13を用いて説明する。本実施形態では、受信したアクセス要求を、まず受信したディスク装置で処理すべきか否か判別する。判別の結果、当該ディスク装置で処理すべきものでなければ、他のディスク装置にアクセス要求を転送する、ことに特徴がある。つまり、本実施形態では、上位装置から記憶装置システムに対するアクセス要求を、記憶装置システムを構成する一台の記憶装置で受領し、更に、当該記憶装置において、アクセス要求を処理すべき記憶装置の判別を実施し、必要な場合、上位装置から記憶装置システムに対するアクセス要求を、処理すべき記憶装置に対して転送することによって、個々の記憶装置を制御する制御装置が不要で低価格な、また、最適な記憶装置の利用効率が期待される高性能な前記記憶装置システムを実現可能にするものである。

[0066]

図9は、前記記憶装置システム4を構成するディスク装置1の一構成例を示す 図である。同図において、上位装置2から受領したアクセス要求を、対を成すディスク装置に転送するか否かを判定制御するコマンド転送制御部29を新たに具備したことを除いては、図2と同一の構成となっている。

[0067]

また、前記協調制御情報28としては、上記上位装置2から受領したアクセス 要求を、対を成すディスク装置に転送するか否かの判定制御を実施する為の情報 等を保持している。更に、前記再送判定部24では、少なくとも、上位装置2か ら記憶装置システム4に対するフレーム等の情報の再送制御として、ライトデー タのフレームを構成するヘッダ情報等に基づく再送(転送)制御を実施するもの である。

[0068]

以下、上位装置から記憶装置システムに対するアクセス要求について、アクセ

ス要求領域を条件として、該アクセス要求を自身が処理すべきか否かを個々のディスク装置で判別する場合のリード/ライトデータ転送処理を例に動作を説明する。

[0069]

図10は、前記ディスク装置1-a/bから構成される記憶装置システム4に対し、上位装置2からのリードデータ要求が発行された場合の、各装置における処理の流れを示す図である。尚、以下の説明では、ディスク装置1-aが上位装置2からのアクセス要求を受領し、該アクセス要求を処理すべき装置の判別、更に、必要な場合、前記アクセス要求をディスク装置1-bに転送に対して転送制御を実施するものとしている。

[0070]

(1)アクセス要求(コマンド)受信

上位装置2から記憶装置システム4に対して発行されたリードデータ要求は、フレーム情報として、先ず、ディスク装置1-aの前記受信部20、及び受信フレーム処理部22を介して、バッファ部12の受信コマンド格納部26に格納される。

[0071]

(2)アクセス要求 (コマンド) 解釈及びアクセス要求 (コマンド) 転送処理 ディスク装置 1-aは、上記受信コマンド格納部 2 6 に格納したアクセス要求を 解釈し、該アクセス要求がリードデータ要求であることを検出する。更に、該リードデータ要求を構成するリード要求領域情報と、前記協調制御情報 2 8 とに基づき、該リードデータ要求を自身が処理すべきか否かを判別する。

[0072]

上記判定で、自身が処理すると判断した場合、アクセス要求はディスク装置1-aで処理される。また、自身で処理しないと判断した場合、ディスク装置1-aは、前記上位装置2からのリードデータ要求をディスク装置1-bに対し転送する。

[0073]

ディスク装置1-bでは、ディスク装置1-aから転送されたリードデータ要求を、受信部20、及び受信フレーム処理部22を介して、バッファ部12の受信コ

マンド格納部26に格納する。更に、ディスク装置1-bは、受信コマンド格納部26に格納したアクセス要求を解釈し、アクセス要求がリードデータ要求であることを検出する。

[0074]

## (3)アクセス要求(コマンド) 実行

自身が処理すると判断したディスク装置 1-a、或いは、ディスク装置 1-aからアクセス要求を転送されたディスク装置 1-bでは、リードデータ要求に基づき、前記ディスク制御部 1 4 を介してディスク部 1 1 からバッファ部 1 2 の送受信データ格納部 2 7 に対するディスクリード処理を開始する。更に、前記インタフェース制御部 1 3 を介して上位装置 2 に対するリードデータ送信処理を実施する。更に、リードデータ送信後、リードデータ要求に対するステータス情報を生成送信し、アクセス要求を削除することによって、一連のリードデータ要求処理を完了する。尚、ディスク装置 1-aにおいて自身が処理しないと判断した場合、リードデータ要求を削除することによって、リードデータ要求に掛かる処理を完了する。

## [0075]

図11は、ディスク装置1-a/bから構成される記憶装置システム4に対し、上位装置2-a/bからのリードデータ要求が発行された場合、特に、上位装置2-aからのリードデータ要求がディスク装置1-aで、上位装置2-bからのリードデータ要求がディスク装置1-bで処理される場合の、リードデータ要求、及び、リードデータの転送処理等の流れを示す図である。

#### [0076]

上述の説明の通り、上位装置 2 -aからのリードデータ要求は、ディスク装置 1 -aによって受領され、ディスク装置 1 -bに転送されることは無い。また、上位装置 2 -bからのリードデータ要求は、上述のディスク装置 1 -aの転送制御処理によって、ディスク装置 1 -bが受領する。

#### [0077]

ディスク装置1-a/bでは、受領したリードデータ要求に対して、ディスク部1 1からのディスクリード処理、及び、上位装置2-a/bに対するリードデータ送信 処理、更に、ステータス生成送信処理を実施する。

[0078]

ここで、ディスク装置 1 -aが送信するリードデータ等は、上位装置 2 -aに対するものであることから、従来通りディスク装置1-bのインタフェース制御部 1 3 を介して上位装置 2 -aに転送される。

[0079]

図12は、ディスク装置1-a/bから構成される記憶装置システム4に対し、上位装置2からのライトデータ要求が発行された場合の、各装置における処理の流れを示す図である。

[0800]

(1) アクセス要求 (コマンド) 受信

上位装置2から記憶装置システム4に対して発行されたライトデータ要求は、フレーム情報として、先ず、ディスク装置1-aの前記受信部20、前記受信フレーム処理部22を介して、バッファ部12の前記受信コマンド格納部26に格納される。

[0081]

(2) アクセス要求 (コマンド) 解釈及びアクセス要求 (コマンド) 転送処理 ディスク装置 1-aは、受信コマンド格納部 2 6 に格納したアクセス要求を解釈 し、アクセス要求がライトデータ要求であることを検出する。更に、該ライトデータ要求を構成するライト要求領域情報と、前記協調制御情報 2 8 とに基づき、該ライトデータ要求を自身が処理すべきか否かを判別する。

[0082]

この判定で、自身が処理すると判断した場合、前記アクセス要求はディスク装置1-aで処理される。また、自身で処理しないと判断した場合、ディスク装置1-aは、上位装置2からのライトデータ要求をディスク装置1-bに転送する。

[0083]

ディスク装置1-bでは、ディスク装置1-aによって転送された前記ライトデータ要求を、前記受信部20、及び前記受信フレーム処理部22を介して、バッファ部12の前記受信コマンド格納部26に格納する。更に、ディスク装置1-bは

、受信コマンド格納部26に格納したアクセス要求を解釈し、該アクセス要求が ライトデータ要求であることを検出する。

[0084]

(3) アクセス要求 (コマンド) 実行 自身が処理すると判断したディスク装置 1-a、或いは、ディスク装置 1-aからアクセス要求を転送されたディスク装置 1-bでは、前記ライトデータ要求に基づき、バッファ部 1 2 の送受信データ格納部 2 7を確保し、上位装置に対しライトデータの転送開始要求を送信する。更に、上記ライトデータの転送開始要求を受信した上位装置から送信されるライトデータを、上記予め確保した送受信データ格納部 2 7 に格納する。

[0085]

更に、ライトデータ受信後、或いは、受信したライトデータを前記ディスク部 11に対しライトするディスクライト処理完了後、前記ライトデータ要求に対す るステータス情報を生成送信する。

[0086]

(4) アクセス要求 (コマンド) 完了処理

ディスク装置 1 -bでは、ステータス情報を生成送信の後、アクセス要求を削除することによって、一連のライトデータ要求処理を完了する。また、ディスク装置 1 -aでは、上記ステータス情報を生成送信の後、或いは、自身で処理しないと判断し、上位装置 2 からのライトデータ要求をディスク装置 1 -bに対し転送した後、ライトデータ要求を構成するライト要求領域情報に基づき、後述の未更新領域管理情報を更新する。更に、アクセス要求を削除することによって、一連のライトデータ要求処理を完了する。

[0087]

本実施形態において、前記ディスク装置 1-a/bから構成される記憶装置システム 4 に対し、上位装置 2-a/bからのライトデータ要求が発行された場合、特に、上位装置 2-aからのライトデータ要求がディスク装置 1-aで、上位装置 2-bからのライトデータ要求がディスク装置 1-bで処理される場合の、ライトデータの転送開始要求、及び、ライトデータの転送処理等の流れは、図 6 と同一であることから省略する。

## [0088]

但し、上述の説明の通り、上位装置 2 -a/bからのアクセス要求は、少なくともディスク装置 1 -aのバッファ部 1 2 に格納され、ディスク装置 1 -aが自身で処理しないと判断した場合に、ディスク装置 1 -bに対して転送されるものである。

## [0089]

上述の通り、本実施形態では、複数の記憶装置から構成される記憶装置システムにおいて、該記憶装置システムを構成する少なくとも一台の記憶装置が、上位装置から記憶装置システムに対するアクセス要求を受領する。更に、当該記憶装置において、アクセス要求を処理すべき記憶装置の判別を実施し、必要な場合、上位装置から記憶装置システムに対するアクセス要求を、処理すべき記憶装置に対して転送する手段を具備することによって、個々の記憶装置を制御する制御装置が不要で低価格な、また、最適な記憶装置の利用効率が期待される高性能な記憶装置システムが実現可能となる。

## [0090]

また、前述の実施形態と同様に、本実施形態でも上位装置 2 からのライトデータ要求によって、一時的にディスク装置 1 -a/bに格納されたデータの不一致が生じてしまう。そこで、以下に本実施形態におけるライトデータの更新処理例を説明する。

## [0091]

本実施形態では、前述の未更新領域管理情報30対して、新たに自身の格納するデータが最新か否かの情報(以下、更新種別情報)を付加した未更新領域管理情報をディスク装置1-aで保持し、ディスク装置1-aにおいて、上位装置からのライトデータ要求を構成するライト要求領域情報に基づき、上記未更新領域管理情報を構成する未更新領域情報と、更新種別情報とを更新・管理することによって、不一致の発生した未更新領域の管理、及び、以降の未更新領域の更新処理を実現するものである。

#### [0092]

図13は、前記ディスク装置1-aの未更新領域管理情報に基づき、不一致の発生した未更新領域の更新処理を実施する場合の、更新要求、及び、更新データの

転送処理等の流れを示す図である。また、同図において、ディスク装置 1-aがディスク装置 1-bに格納された最新のデータを用いて、自身を更新する場合を例としている。

## [0093]

ディスク装置1-aは、少なくとも、未更新領域情報と更新種別情報とから構成される前記未更新領域管理情報に基づき、対を成すディスク装置1-bに対し、更新要求(最新データ送信要求)を発行する。該更新要求を受領したディスク装置1-bでは、必要ならば前記ディスク部11からのディスクリードを実施し、要求対象のデータをディスク装置1-aに対し送信する。ディスク装置1-aでは、上記ディスク装置1-bから受信したデータをディスク部11に格納し、当該処理に掛かる未更新領域情報を前記未更新領域管理情報30から削除することによって、未更新領域の更新処理を完了する。

## [0094]

また、ディスク装置 1-aが自身の格納する最新データを用いて、ディスク装置 1-bを更新する場合、ディスク装置 1-aは、前記未更新領域管理情報に基づき、対を成すディスク装置 1-bに対し、更新要求(最新データ受信要求)を発行し、引き続き更新対象のデータを送信する。更新要求及び更新対象データを受領したディスク装置 1-bでは、上記ディスク装置 1-aから受信したデータをディスク部 1 1 に格納する。更に、ディスク装置 1-aは、更新対象データの送信後、当該処理に掛かる未更新領域情報を前記未更新領域管理情報 3 0 から削除することによって、未更新領域の更新処理を完了する。

#### [0095]

以上の実施形態では、上位装置から記憶装置システムに対するアクセス要求を 構成するアクセス要求領域を条件として、該アクセス要求を自身が処理すべきか 否かを判別する場合を例に動作を説明してきたが、これに限定するものではない

## [0096]

例えば、記憶装置がオブジェクト(ファイル)単位で格納するデータを管理する場合、上位装置から記憶装置システムに対するアクセス要求を構成するオブジ

ェクト (ファイル) 情報を条件として、該アクセス要求を自身が処理すべきか否かを判別することが可能であり、前記未更新領域管理情報として少なくとも保持する未更新領域情報も、オブジェクト (ファイル) 情報を用いることで、上述の未更新領域の更新処理を実現することが可能となる。

## [0097]

また、以上の実施形態では、複数の記憶装置から構成されるRAID1の記憶装置システムにおいて、当該記憶装置システムを構成する個々の記憶装置が、或いは、少なくとも一台の記憶装置が、上位装置から記憶装置システムに対するアクセス要求について、自身が処理すべきか否かを判別する手段を具備することによって、個々の記憶装置を制御する制御装置を不要とする。また、最適な記憶装置の利用効率が期待される高性能な前記記憶装置システムを実現するものである。

## [0098]

しかし、最適な記憶装置の利用効率を実現する為、上位装置からのライトデータ要求によって、一時的にではあるが、二重化されたディスク装置のデータに不一致が生じ、上記ライトデータの更新処理を必要とする場合もある。また、上記上記ライトデータの更新処理において、前記インタフェース3を介したライトデータの転送処理を実施する為、インタフェース3の負荷を軽減するものではない

## [0099]

そこで、上位装置2から記憶装置システム4に対するアクセス要求、特に、ライトデータ要求を、該記憶装置システム4を構成する複数の記憶装置1で共有し、更に、対を成す複数の記憶装置が同期して該ライトデータ要求を処理することによって、インタフェース負荷を軽減することによる高性能化を図った実施形態について、以下に説明する。

#### [0100]

以下、本発明に係る第三の実施形態を、図14、15を用いて説明する。

本実施形態では、上位装置2から記憶装置システム4に対するライトデータ要求を、該記憶装置システム4を構成する複数の記憶装置1で共有し、更に、を成す複数の記憶装置でライトデータの転送処理をも同期して実施することによって

、個々の記憶装置を制御する制御装置が不要で低価格な、また、インタフェース 負荷を軽減する高性能な前記記憶装置システムを実現するものである。

## [0101]

尚、本実施形態の記憶装置システムを構成する記憶装置(ディスク装置)の構成は、再送判定制御部24において、上位装置2から記憶装置システム4に対するフレーム等の情報の再送制御として、ライトデータについても、前記協調制御情報28に基づく再送制御を実施することを除いて、図2と同一であることから省略する。

#### [0102]

また、上位装置から記憶装置システムに対するリードデータ要求については、 本実施形態の対象外であり、上述の実施形態の何れかを採用するものとして、そ の説明も省略する。

#### [0103]

以下、上位装置から記憶装置システムに対するライトデータ要求について、対 を成す二台の記憶装置でライトデータの転送処理を同期して実施する場合のライ トデータ転送処理を例に動作を説明する。

図14は、前記ディスク装置1-a/bから構成される記憶装置システム4に対し、上位装置2からのライトデータ要求が発行された場合の、各装置における処理の流れを示す図である。

#### [0104]

図15は、前記ディスク装置1-a/bから構成される記憶装置システム4に対し、上位装置2からのライトデータ要求が発行された場合の、ライトデータ要求、ライトデータの転送開始要求、及び、ライトデータの転送処理等の流れを示す図である。

#### [0105]

(1) アクセス要求(コマンド) 受信及び再送処理

上位装置2から記憶装置システム4に対して発行されたライトデータ要求は、 フレーム情報として、先ず、ディスク装置1-aの前記受信部20を介して受信される。 ディスク装置1-aでは、前記ライトデータ要求を、前記受信フレーム処理部2 2を介して、前記バッファ部12の前記受信コマンド格納部26に格納する。

[0106]

また、ディスク装置1-aの前記再送判定部24は、前記協調制御情報28に基づき、上位装置から記憶装置システム4に対するアクセス要求を後段のディスク装置1-bに対して再送するように設定しておくことによって、受信したフレーム情報がアクセス要求であることを検出し、前記出力選択部25に対する再送制御(指示)信号を生成する。結果、前記出力選択部25は、該再送制御(指示)信号に基づき、前記上位装置からのライトデータ要求を後段のディスク装置1-bに対し再送する。

[0107]

ディスク装置 1-bでは、前記ディスク装置 1-aによって再送された前記ライトデータ要求を、前記受信フレーム処理部 2 2 を介して、前記バッファ部 1 2 の前記受信コマンド格納部 2 6 に格納する。また、ディスク装置 1-bの前記再送判定部 2 4 は、前記協調制御情報 2 8 に基づき、アクセス要求を後段の装置に対し再送しないよう設定されている。

[0108]

(2) アクセス要求(コマンド)解釈及びアクセス要求(コマンド) 実行

ディスク装置 1-a/bは、前記受信コマンド格納部 2 6 に格納したアクセス要求を解釈し、該アクセス要求がライトデータ要求であることを検出し、バッファ部 1 2 の送受信データ格納部 2 7 を確保する。ディスク装置 1-aでは、自身の送受信データ格納部 2 7 を確保したことを契機として、ディスク装置 1-bに対しライトデータの転送開始要求を送信する。一方、ディスク装置 1-bでは、自身の送受信データ格納部 2 7 を確保したことと、ディスク装置 1-aからのライトデータの転送開始要求受信を契機として、上位装置 2 に対しライトデータの転送開始要求を送信する。

[0109]

上位装置2では、上記ライトデータの転送開始要求を受信したことを契機として、ライトデータの送信を開始する。

上位装置2から送信されたライトデータは、先ず、ディスク装置1-aの前記受信部20を介して受信される。ディスク装置1-aでは、上記ライトデータを、前記受信フレーム処理部22を介して、バッファ部12の前記送受信データ格納部27に格納する。

## [0110]

また、ディスク装置 1-aの再送判定部 2 4 は、協調制御情報 2 8 に基づき、上位装置 2 から記憶装置システム 4 に対するライトデータを後段のディスク装置 1-bに対して再送するように設定しておくことによって、受信したフレーム情報がライトデータであることを検出し、出力選択部 2 5 に対する再送制御(指示)信号を生成する。出力選択部 2 5 は、再送制御(指示)信号に基づき、上位装置からのライトデータを後段のディスク装置 1-bに対し再送する。

## [0111]

ディスク装置 1-bでは、ディスク装置 1-aによって再送されたライトデータを、受信フレーム処理部 2 2 を介して、バッファ部 1 2 の前記送受信データ格納部 2 7 に格納する。また、ディスク装置 1-bの再送判定部 2 4 は、協調制御情報 2 8 に基づき、ライトデータを後段の装置に対し再送しないよう設定されている。

## [0112]

ディスク装置 1-aでは、ライトデータ受信後、或いは、受信したライトデータをディスク部 1 1 に対しライトするディスクライト処理完了後、ディスク装置 1-bに対し、前記ライトデータ要求に対するステータス情報を生成送信する。更に、当該ライトデータ要求を削除することによって、一連のライトデータ要求処理を完了する。

## [0113]

ディスク装置 1-bでは、ライトデータ受信後、或いは、受信したライトデータをディスク部 1 1 に対しライトするディスクライト処理完了後、ディスク装置 1 からのステータス情報を受信後、上位装置 2 に対して当該ライトデータ要求に対するステータス情報を生成送信し、更に、当該ライトデータ要求を削除することによって、一連のライトデータ要求処理を完了する。

## [0114]

上述の通り、本実施形態では、複数の記憶装置から構成されるRAID1の記憶装置システムにおいて、該記憶装置システムを構成する個々の記憶装置が、少なくとも上位装置から記憶装置システムに対するライトデータ要求を共有する手段と、上記共有したライトデータ要求について、対を成す複数の記憶装置間でライトデータの転送処理と、当該ライトデータ要求に対するステータス情報の送信処理とを同期して実施する手段とを具備することによって、個々の記憶装置を制御する制御装置が不要で低価格な、また、記憶装置間でのデータ更新処理を不要とし、インタフェース負荷を軽減する高性能な前記記憶装置システムが実現可能となる。

## [0115]

以上の実施形態では、本発明を適用した複数の記憶装置のみから構成される、RAID1の記憶装置システムについて述べてきたが、これに限定されるものではない。例えば、従来のディスクアレイ装置、即ち、複数のディスク装置と、これらのディスク装置を制御する制御装置とから構成されるディスクアレイ装置においても、本発明を適用したディスク装置を採用することによって、上記制御装置の構成が容易となり、結果、低価格化を実現することが可能となる。

## [0116]

更に、前述の上位装置からのアクセス要求を自身が処理すべきか否かの判別処理の一例を、以下に説明する。

## [0117]

図16は、前記協調制御情報28を構成する情報の一例を示す図である。

同図において、協調制御情報28を構成する情報として、前記記憶装置システム4の装置識別情報と、個々の記憶装置自身に固有の装置識別情報と、自身と協調制御を実施する記憶装置に固有の装置識別情報と、協調処理モード情報と、更に、協調処理対象となる領域管理情報として、協調領域サイズ情報と、アクティブ領域開始アドレス情報と、アクティブ領域サイズ情報とを保持するものである

## [0118]

また、上記各情報について、記憶装置1-a/bにおける設定例を示しており、前

記記憶装置システム4の装置識別情報は、記憶装置 1-a/bともにID\_0、個々の記憶装置自身に固有の装置識別情報は、記憶装置 1-aにID\_1、記憶装置 1-bにID\_2、自身と協調制御を実施する記憶装置に固有の装置識別情報は、記憶装置 1-aにID\_2、記憶装置 1-bにID\_1を設定し、協調処理モード情報は、記憶装置 1-aにコマンド再送、記憶装置 1-bにコマンド受領を設定し、更に、協調領域サイズ情報はNとして、アクティブ領域開始アドレス情報は、記憶装置 1-aに 0、記憶装置 1-bにN/2、アクティブ領域サイズ情報は、記憶装置 1-a/bともにN/2を設定したものである。

#### [0119]

尚、上記記憶装置システム4の装置識別情報と、個々の記憶装置自身に固有の装置識別情報と、自身と協調制御を実施する記憶装置に固有の装置識別情報と、協調処理モード情報とは、後述のフレームデータ再送処理判定で用いられる協調制御情報である。

## [0120]

図17は、前記上位装置からのアクセス要求情報として、FCP (Fibre Channel Protocol)で規定されるアクセス要求情報の構成例を示す図である。同図において、上記アクセス要求情報は、アクセス要求対象領域の開始アドレス情報(図中、Logical Block Address)と、アクセス要求対象領域サイズ情報(Transfer Length)を含むものである。

## [0121]

上位装置からのアクセス要求情報を受領した記憶装置1は、自身の保持する前記協調制御情報の、アクティブ領域開始アドレス情報と、アクティブ領域サイズ情報と、上記上位装置からのアクセス要求情報の、アクセス要求対象領域の開始アドレス情報と、アクセス要求対象領域サイズ情報とに基づき、該アクセス要求を自身が処理すべきか否か、即ち、自身のアクティブ領域に対するアクセス要求か否かを判別し、自身のアクティブ領域に対するアクセス要求の否かを判別し、自身のアクティブ領域に対するアクセス要求についてのみ、処理を実施する。

## [0122]

例えば、上記上位装置からのアクセス要求対象領域が、N/2以下の場合、記

憶装置#1が、また、N/2以上の場合、記憶装置#2が、該上位装置からのアクセス要求を処理する。更に、上記上位装置からのアクセス要求対象領域が、記憶装置#1及び記憶装置#2のアクティブ領域に係る場合、記憶装置#1及び記憶装置#2が、夫々自身のアクティブ領域に対するアクセス要求を処理する。

## [0123]

また、上述の実施形態では、協調処理対象領域の管理情報として、アドレス情報と、サイズ情報とを保持し、上位装置からのアクセス要求情報を構成するアドレス情報と、サイズ情報とに基づき、該アクセス要求を自身が処理すべきか否かを判別する場合を例に説明したが、これに限るものではなく、例えば、図17に示す論理ユニット番号(図中、FCP\_LUN or Logical Unit Number)を条件とすることも可能であり、この場合、前記記憶装置1は、前記協調制御情報28を構成する協調処理対象領域に関する管理情報として、アクティブ論理ユニット番号情報を保持するものである。

## [0124]

更にまた、上位装置からのアクセス要求情報が、ファイル名等のオブジェクト名を保持する場合、前記記憶装置1は、前記協調制御情報28を構成する協調処理対象領域に関する管理情報として、アクティブオブジェクトリスト情報を保持することによって、オブジェクト単位で、上記上位装置からのアクセス要求を自身が処理すべきか否かを判別することも可能である。

#### [0125]

尚、前述の第二の実施形態においては、上位装置からのアクセス要求対象領域が、ディスク装置1-a及び前記ディスク装置1-bのアクティブ領域に係る場合、ディスク装置1-aが、上位装置からのアクセス要求情報を、ディスク装置1-bのアクティブ領域に対するアクセス要求に加工して前記ディスク装置1-bに対して送信することによって、ディスク装置1-a/bでの協調制御処理を実現することが可能である。

## [0126]

或いは、前記ディスク装置1-bにおいて、前述の協調制御情報(アクティブ領域開始アドレス情報、アクティブ領域サイズ情報、等)を保持し、前記上位装置

からのアクセス要求情報の、アクセス要求対象領域情報とに基づき、該アクセス 要求を自身が処理すべきか否か、即ち、自身のアクティブ領域に対するアクセス 要求か否かを判別し、自身のアクティブ領域に対するアクセス要求について処理 を実施することによって、上述の前記ディスク装置1-aが、前記上位装置からの アクセス要求情報を、ディスク装置1-bのアクティブ領域に対するアクセス要求 に加工してディスク装置1-bに対して送信することなく、前記ディスク装置1-a /bでの協調制御処理を実現することが可能である。

## [0127]

更に、前述の上位装置と記憶装置システムとの間で転送されるフレームデータ 等の情報を後段の装置に対して再送するか否かの判定処理の一例を、以下に説明 する。

## [0128]

図18は、上位装置と記憶装置システムとの間で転送される情報として、FC-P H (Fibre Channel PHYSICAL AND SIGNALING INTERFACE)で規定されるフレームへッダ情報の構成例を示す図である。

## [0129]

同図において、上記フレームヘッダ情報は、フレームデータの送信先/送信元の情報 (D\_ID: Destination\_Identifier、S\_ID: Source\_Identifier) と、フレームデータ種別情報 (R\_CTL: Routing Control、TYPE: Data structure type) と、フレームデータの関連するイクスチェンジ識別情報 (RX\_ID: Responder Exchange\_Identifier、OX\_ID: Originator Exchange\_Identifier) のフィールドを具備している。

## [0130]

先ず、前記記憶装置システム4 (前記ディスク装置 1-a/b) から上位装置に対して送信されるフレームデータ (リードデータ、ライトデータの転送開始要求、ステータス情報、等) の場合、上記フレームヘッダ情報のフレームデータの送信 先情報 (D\_ID) として、上位装置の識別情報が設定されており、当該フレームデータを受信したディスク装置は、再送する。

## [0131]

そこで、以下では、上位装置から前記記憶装置システム4に対して送信される、即ち、前記フレームヘッダ情報のフレームデータの送信先情報 (D\_ID) として、記憶装置システム4の識別情報が設定されたフレームデータ (アクセス要求、ライトデータ)を対象に、再送判定処理の一例を説明する。

[0132]

## (1) アクセス要求

再送判定部24では、上位装置から記憶装置システム4に対するフレームデータ(アクセス要求)を受信した際、前記フレームヘッダ情報のフレームデータ種別情報(R\_CTL、TYPE)から、当該フレームデータがアクセス要求であることを検出し、更に、前記協調制御情報28を構成する協調処理モード設定情報(コマンド再送、且つ或いは、コマンド受領)に基づき、該受信したアクセス要求を後段の装置に対して再送するか否かを決定することで、フレームデータ(アクセス要求)の再送処理を実現する。

[0133]

## (2) ライトデータ

再送判定部24では、上位装置から記憶装置システム4に対するフレームデータ(ライトデータ)を受信した際、前記フレームヘッダ情報のフレームデータ種別情報(R\_CTL、TYPE)から、当該フレームデータがライトデータであることを検出し、更に、前記フレームヘッダ情報のフレームデータの送信元情報(S\_ID)と、イクスチェンジ識別情報(RX\_ID、OX\_ID)とが、後述のライト処理管理情報に登録されたものと一致するか否かを検出し、一致する場合、該ライトデータを受領し、不一致の場合、後段の装置に対して再送することで、フレームデータ(ライトデータ)の再送処理を実現する。

[0134]

図19は、上記ライト処理管理情報の一構成例を示すものであり、実行中(処理未完)のライト処理の前記イクスチェンジ識別情報(RX\_ID、OX\_ID)と、アクセス要求発行元上位装置の識別情報(Host ID)とを関連付けたものを、ライト処理管理情報として保持する例である。同図において、例えば、同一の上位装置(Host ID(S\_ID) = ID\_3)から、前記記憶装置システム4に対して送信される

ライトデータフレームは、該フレームヘッダを構成する前記イクスチェンジ識別情報 (RX\_ID and/or OX\_ID) が、上記ライト処理管理情報に登録されたものと一致するか否かを検出することで、自身が受領すべきライトデータフレームか否かの検出が可能となる。

## [0135]

尚、上記ライト処理管理情報の最少の構成例としては、実行中(処理未完)のライト処理の前記イクスチェンジ識別情報(OX\_ID)と、アクセス要求発行元上位装置の識別情報(Host ID)とから構成することも可能であるが、上記OX\_IDは上位装置側で設定する値であり、その独立性を保障されるものではない。これに対し、前記RX\_IDは記憶装置側で任意の値を設定可能であることから、前記ライト処理管理情報として保持することが望ましく、更に、協調制御の対象となる記憶装置間で異なる値を取るように設定することが望ましい。

#### [0136]

次に、本発明の第四の実施の形態について説明する。

第四の実施形態は、記憶装置サブシステムを構成する個々の記憶装置が、複数の記憶装置間で協調して上位装置からのアクセス要求を処理するための制御情報 (協調制御情報)と、上位装置から記憶装置サブシステムに対するアクセス要求情報とに基づき、当該アクセス要求を自身が処理すべきか否かの判別を実施するものである。

## [0137]

第五の実施形態は、第四の実施形態の記憶装置が、更に、協調して処理する他の記憶装置の動作状態情報を追加保持することによって、前記記憶装置サブシステムを構成する記憶装置に障害が発生した場合でも、上位装置から記憶装置サブシステムに対するアクセス要求処理を実現するものである。

#### [0138]

第六の実施形態は、上述の実施形態の記憶装置が、更に、複数のインタフェース制御部を具備し、上位装置からのアクセス要求情報と、記憶装置サブシステムを構成する記憶装置間で転送されるユーザデータとの転送処理を、異なるインタフェース(伝送路)を用いて実現するものである。

## [0139]

[第四の実施形態] (正常動作)

以下、本発明に係る第四の実施形態を、図20~14を用いて説明する。

図20は、複数(N, N>1)台の記憶装置1から構成される記憶装置サブシステム4と、上位装置2とから構成される情報処理システムの一例を示す図であり、同図において、記憶装置サブシステム4を構成する個々の記憶装置1は、前記上位装置2と、巡回型(以下、ループ)のインタフェース3を介して直接接続されている。

#### [0140]

また、同図において、記憶装置1としてディスク装置を例に構成を示しており、該ディスク装置1は、夫々前記上位装置2がアクセスするデータを保持する記憶媒体であるディスク部11と、該ディスク部11と前記上位装置2との間で転送されるデータを一時保持するバッファ部12と、前記上位装置2との間のインタフェースプロトコル制御を実行するインタフェース制御部13と、前記ディスク部11に対する記録再生処理を実行するディスク制御部14と、前記バッファ部12に対するアクセスを制御するバッファ制御部15と、上位装置からのデータライト要求に基づき受信したライトデータ(新データ)と、前記ディスク部に格納済みの更新対象データ(旧データ)とから排他的論理和演算による更新情報を生成する更新情報生成部16と、上記各部位を統括制御するメイン制御部10とを具備する構成である。

#### [0141]

図21は、前記記憶装置システム4を構成するディスク装置1の一構成例を示す図である。

## [0142]

同図において、前記インタフェース制御部13は、前記インタフェース3を介して情報の受信を実施する受信部20と、同様に情報の送信を実施する送信部21と、受信したフレーム等の情報に対するエラー検出、或いは、該フレーム情報の少なくとも一部を前記バッファ部12に格納する際、格納先の制御等を実施する受信フレーム処理部22と、フレーム等の情報送信の際、該フレーム情報を構

成するヘッダ情報等の付加情報の生成を実施する送信フレーム生成部23とを具備し、

更に、前記受信部20で受信したフレーム等の情報を後段の装置に対し再送するか否か、或いは、自身が受領するか否かの制御(再送制御)を実施するフレーム受信制御部24と、該フレーム受信制御部24から再送された情報と、前記送信フレーム生成部23からの情報との一方を選択し、前記送信部21に出力するフレーム送信制御部25とを具備する。

# [0143]

また、前記バッファ部12は、上位装置2から受信したアクセス要求(コマンド)を保持する受信コマンド格納部26と、上位装置2との間で送受信されるデータを保持する送受信データ格納部27と、前記更新情報生成部16にて生成された更新情報を保持する更新情報格納部28とを具備する。

# [0144]

また、前記メイン制御部10は、後述の協調制御情報29と、上位装置2から 記憶装置システム4に対するアクセス要求情報とに基づき、該アクセス要求に対 応する自身の処理を制御する協調処理制御部30を具備している。

#### [0145]

尚、前記フレーム受信制御部24における再送制御は、上記協調処理制御部3 0からの制御情報と、フレームを構成するヘッダ情報等に基づき実施するものである。

#### [0146]

図22は、前記協調制御情報29の構成、及び個々の記憶装置における設定の一例を示す図である。同図において、該協調制御情報29は、前記記憶装置サブシステム4の装置識別情報(共有ID)と、個々の記憶装置自身に固有の装置識別情報(固有ID)と、前記巡回型インタフェース3における相対位置情報としてのポジションマップ情報と、前段から受信したアクセス要求フレームを後段の装置に対し再送するか否かモードを指定するコマンド転送モード情報とを含む。

#### [0147]

更に、冗長構成の管理情報として、RAIDレベル情報と、冗長データ管理サ

イズと、前記記憶装置サブシステム4を構成ディスク台数構成情報であるデータ ディスク台数/冗長データディスク台数情報とから構成され、個々の記憶装置毎 に任意の設定が実施されている。

[0148]

図23は、前記巡回型インタフェース3の一例として、Fibre Channel Arbitr ated Loop (FC-AL)におけるフレーム情報の構成を示す図である。

[0149]

同図において、フレーム情報は、フレーム情報の開始を示すSOF (Start of Frame)と、フレーム情報の種別情報、並びに、送信先/元情報等を含むヘッダ情報と、装置間で転送されるペイロード(ユーザデータ)と、上記ヘッダ情報と、ペイロードに対する冗長データであるCRC (Cyclic Redundancy Check)と、フレーム情報の終了を示すEOF (End of Frame)とから構成されている。

[0150]

図24は、上記ヘッダ情報の一例を示す図であり、フレーム情報の種別情報であるR\_CTL/TYPE、フレーム情報の送信先/元情報であるD\_ID/S\_ID等から構成されている。

[0151]

図25は、上記ペイロードとして、アクセス要求情報の一例を示す図であり、 アクセス要求の対象を指定する情報である論理ユニット番号(FCP\_LUN)、アドレス情報(Logical Block Address)、転送長情報(Transfer Length)、アクセス要求 の種別情報であるオペレーションコード(Operation Code)等から構成されている

[0152]

以下、前記上位装置2から記憶装置サブシステム4に対するアクセス要求を、 前記記憶装置1-1~Nが協調して処理する動作を説明する。

[0153]

(1) アクセス要求(コマンド) 受信及び再送処理

図26は、前記記憶装置1-1~Nから構成される記憶装置サブシステム4に対し、上位装置2からのアクセス要求が発行された場合の、各記憶装置における

処理例を示す図である。

#### [0154]

先ず、上位装置2から記憶装置サブシステム4に対して発行されたアクセス要求(Command)は、フレーム情報として、記憶装置1-1の前記受信部20を介して受信される。

# [0155]

記憶装置1-1では、上記アクセス要求を、前記フレーム受信制御部24、並びに受信フレーム処理部22を介して、前記バッファ部12の前記受信コマンド格納部26に格納する。

#### [0156]

また、記憶装置1-1の前記フレーム受信制御部24は、前記協調制御情報29の前記コマンド転送コードを上位装置2から記憶装置サブシステム4に対するアクセス要求を後段の装置に対して再送するよう(受信&再送)に設定しておくことによって、受信したフレーム情報の前記ヘッダ情報から、該フレーム情報がアクセス要求であることを検出し、前記フレーム送信制御部25を介して、前記上位装置からのアクセス要求を後段の装置に対し再送する(受信&再送)。

#### [0157]

後段の記憶装置 $1-2\sim(N-1)$  においても、上記と同様のコマンド受信を再送処理を実施する。

#### [0158]

最終段の記憶装置1-Nでは、前記協調制御情報29の前記コマンド転送コードを上位装置2から記憶装置サブシステム4に対するアクセス要求を後段の装置に対して再送しないよう(受信のみ)に設定しておくことによって、受信したフレーム情報の前記ヘッダ情報から、該フレーム情報がアクセス要求であることを検出し、を後段の装置に対し再送することなく、前記バッファ部12の前記受信コマンド格納部26への格納のみ実施する。

#### [0159]

以上のアクセス要求(コマンド)受信及び再送処理によって、協調処理を行う 各記憶装置1-1~Nで、新たなアクセス要求の転送処理を開始することなく、 上位装置2からのアクセス要求を共有することが可能となる。

[0160]

(2-1) リード処理(1台の記憶装置で処理実現)

図27は、上位装置2からの前記アクセス要求が、リードデータ要求で、且つ、一台の記憶装置で処理可能な場合のデータ転送処理例を示す図であり、同図においては、記憶装置1-2がデータ送信処理(Data2送信)を実施するものとしている。

#### [0161]

各記憶装置1-1~Nは、前記受信コマンド格納部26に格納したアクセス要求情報と前記協調制御情報29とに基づき、該アクセス要求を自身が処理するか否かを判別する。

#### [0162]

自身が処理すると判断した記憶装置1-2では、前記ディスク制御部14-2を介してディスク部11-2から前記バッファ部12-2の前記送受信データ格納部27-2に対するディスクリード処理を開始し、更に、前記インタフェース制御部13-2を介して上位装置2に対するリードデータ送信処理を実施する。更に、リードデータ送信後、前記アクセス要求に対するステータス情報を生成送信し、前記アクセス要求を削除することによって、一連のリードデータ要求処理を完了する。

# [0163]

一方、自身が処理しないと判断したディスク装置では、前記アクセス要求を削 除することによって、リードデータ要求に掛かる処理を完了する。

尚、記憶装置1-2の後段に位置する記憶装置1-3~Nにおいては、記憶装置1-2から送信されるフレーム情報(リードデータ、ステータス)について、そのヘッダ情報から再送処理のみを実施する。

#### [0164]

(2-2) リード処理(複数台の記憶装置で処理実現)

図28は、上位装置2からの前記アクセス要求が、リードデータ要求で、且つ、複数台の記憶装置での処理が必要な場合の、各記憶装置におけるデータ転送処

理例を示す図であり、同図においては、記憶装置1-1/2がデータ送信処理(Data1/Data2送信)を実施するものとしている。

# [0165]

図29は、複数台の記憶装置でのデータ転送処理が必要な場合の、データフレーム (ペイロード) 情報の一構成例を示す図であり、従来、データフレーム (ペイロード) がユーザデータのみから構成されていたのに対し、上記ユーザデータを処理対象の記憶装置毎に分割したユーザデータセグメント0~nと、該ユーザデータセグメントのデータが有効か否かを示すフラグ(Data Valid bit)とから構成するものとしている。

#### [0166]

尚、以下の説明では、前記アクセス要求情報と前記協調制御情報29とに基づき、前記アクセス要求を処理する記憶装置において、最前段に位置する(上位装置からの情報を最も早く受信する)記憶装置が、リードデータ/ステータス情報の送信開始を許可する場合を例に説明するが、これに限るものではなく、任意のアルゴリズムでリードデータの送信を開始する記憶装置を決定することが可能である。

#### [0167]

前述と同様に、各記憶装置1-1~Nは、前記受信コマンド格納部26に格納したアクセス要求情報と前記協調制御情報29とに基づき、該アクセス要求を自身が処理するか否かを判別し、自身が処理しないと判断したディスク装置では、前記アクセス要求を削除することによって、リードデータ要求に掛かる処理を完了する。

# [0168]

自身が処理すると判断した記憶装置1-1/2では、前記ディスク制御部14-1/2を介してディスク部11-1/2から前記バッファ部12-1/2の前記送受信データ格納部27-1/2に対するディスクリード処理を開始する。

#### [0169]

自身がリードデータの送信の開始を許可された記憶装置1-1では、上位装置 2に対するリードデータの送信処理として、例えば、前記ユーザデータセグメン ト O に自身のリードデータを、他のユーザデータセグメント(1)にはダミーデータを格納し、更に、前記ユーザデータセグメント O に対応するフラグに "有効"を、他のユーザデータセグメントに対応するフラグに "無効"を設定した前記データフレーム情報の送信処理を実施し、更に、該処理に係るステータス情報の生成送信後、前記アクセス要求を削除することによって、一連のリードデータ要求処理を完了する。

# [0170]

また、自身がリードデータの送信の開始を禁止された記憶装置1-2では、上位装置2に対するリードデータの送信処理として、例えば、上記記憶装置1-1から受信したリードデータフレームのユーザデータセグメント1に自身のリードデータを格納し、更に、前記ユーザデータセグメント1に対応するフラグに"有効"を設定した前記データフレーム情報の送信処理を実施し、更に、該処理に係るステータス情報と前段の装置から受信したステータス情報とに基づく新たなステータス情報を生成送信後、前記アクセス要求を削除することによって、一連のリードデータ要求処理を完了する。

# [0171]

尚、上記データ送信処理を実施する最終段の記憶装置、即ち、上位装置に対する最終形のデータフレーム情報を生成する記憶装置においては、前記ユーザデータセグメントのデータが有効か否かを示すフラグ(Data Valid bit)領域を削除して、ユーザデータのみから構成されるペイロードとして上位装置に送信することが望ましい。

#### [0172]

また、上位装置2に対するステータス情報の送信処理としては、上記データ送信処理を実施する最終段の記憶装置、即ち、上位装置に対する最終形のデータフレーム情報を生成する記憶装置において、前段の装置から受信したステータス情報と自身のステータス情報とから新たなステータス情報を生成送信することによって、上位装置2に対するステータス情報の生成を実現している。

#### [0173]

(2-3) ライト処理(1台の記憶装置でデータ更新処理実現)

図30は、上位装置2からの前記アクセス要求が、ライトデータ要求で、且つ、一台の記憶装置のデータ更新処理と一台の記憶装置の冗長データ更新処理とを実施する場合のデータ転送処理例を示す図であり、同図においては、記憶装置1-1がデータ更新処理(Data10→Data1N)を記憶装置1-Nが冗長データ更新処理(DataP0→DataPN)を実施するものとしている。

# [0174]

前述と同様に、各記憶装置1-1~Nは、前記受信コマンド格納部26に格納 したアクセス要求情報と前記協調制御情報29とに基づき、該アクセス要求を自 身が処理するか否か、或いは、該アクセス要求に伴う冗長データ更新処理を実施 するか否かを判別し、自身が処理しないと判断したディスク装置では、前記アク セス要求を削除することによって、上記ライトデータ要求に掛かる処理を完了す る。

#### [0175]

自身がデータ更新処理を実施すると判断した記憶装置 1 - 1 では、前記ディスク制御部 1 4 - 1 を介して、ディスク部 1 1 - 1 に格納されている更新対象のデータ (旧データ: Data10) に対するディスクリード処理を開始する。

# [0176]

更に、上位装置2から前記インタフェース制御部13-1を介して受信したデータ(新データ:Data1N)と上記旧データ(Data1O)とから、例えば、排他的論理和演算結果等による更新情報(Data1N')を前記更新情報生成部16-1で生成する。

#### [0177]

更に、前記上位装置2から受信した新データ(Data1N)を上記更新情報(Data1N')に置換え、当該更新情報を格納するセグメントに対応するフラグに"有効"を 設定した前記Data Valid bit領域を付加した前記データフレーム情報の送信処理 を実施する。

#### [0178]

更に、記憶装置1-1では、上記新データ(Data1N)を、前記ディスク制御部14-1を介してディスク部11-1に格納することによって、データ更新処理を

実現する。

#### [0179]

更に、記憶装置1-1では、上述の処理に係るステータス情報の生成送信後、 前記アクセス要求を削除することによって、一連のライトデータ要求処理を完了 する。

#### [0180]

また、自身が冗長データ更新処理を実施すると判断した記憶装置1-Nでは、前記ディスク制御部14-Nを介して、ディスク部11-Nに格納されている更新対象の冗長データ(旧冗長データ:DataPO)に対するディスクリード処理を開始する。

#### [0181]

更に、前記記憶装置 1-1から受信した更新情報(Data1N')と上記旧冗長データ(DataPO)とから、例えば、排他的論理和演算結果等による新冗長データ(DataPN)を前記更新情報生成部 16-Nで生成し、該新冗長データ(DataPN)を、前記ディスク制御部 14-Nを介してディスク部 11-Nに格納することによって、冗長データ更新処理を実現する。

#### [0182]

更に、記憶装置1-Nでは、上述の処理に係るステータス情報と前段の装置から受信したステータス情報とに基づく新たなステータス情報を生成し、上位装置2に対して送信処理を実施した後、前記アクセス要求を削除することによって、一連のリードデータ要求処理を完了する。

#### [0183]

尚、上記冗長データの更新処理に当っては、前記Data Valid bit領域の対応するフラグが"有効"に設定されているか否かを検出し、"有効"に設定されている場合についてのみ冗長データの更新処理を実施し、"無効"の設定が残っている場合は受信したデータフレーム情報を後段の装置に対して再送することによって、例えば、冗長データ更新を実施する記憶装置の後段にデータ更新処理対象の記憶装置が位置する場合でも、上記データ更新処理/冗長データ更新処理を実現することが可能となる。

[0184]

(2-4) ライト処理(複数台の記憶装置でデータ更新処理実現)

図31は、上位装置2からの前記アクセス要求が、ライトデータ要求で、且つ、複数台の記憶装置のデータ更新処理と一台の記憶装置の冗長データ更新処理とを実施する場合のデータ転送処理例を示す図であり、同図においては、記憶装置1-1/2がデータ更新処理(Data10/20→Data1N/2N)を、記憶装置1-Nが冗長データ更新処理(DataPO→DataPN)を実施するものとしている。

[0185]

前述と同様に、各記憶装置1-1~Nは、前記受信コマンド格納部26に格納 したアクセス要求情報と前記協調制御情報29とに基づき、該アクセス要求を自 身が処理するか否か、更に、該アクセス要求に伴う冗長データ更新処理を実施す るか否かを判別し、自身が処理しないと判断したディスク装置では、前記アクセ ス要求を削除することによって、上記ライトデータ要求に掛かる処理を完了する

[0186]

自身がデータ更新処理を実施すると判断した記憶装置1-1では、前記ディスク制御部14-1を介して、ディスク部11-1に格納されている更新対象のデータ(旧データ:Data10)に対するディスクリード処理を開始する。

[0187]

更に、上位装置 2 から前記インタフェース制御部  $1 \ 3 - 1 \$ を介して受信したデータ (新データ: Data  $1 \ N/2 \$ ) のうち、自身の新データ (Data  $1 \ N/2 \$ ) と上記旧データ (Data  $1 \ N/2 \$ ) とから、例えば、排他的論理和演算結果等による更新情報 (Data  $1 \ N/2 \$ ) を前記更新情報生成部  $1 \ 6 - 1 \$ で生成する。

[0188]

更に、前記上位装置 2 から受信した新データ (Data1N/2N)の内、自身に対する新データ (Data1N)を上記更新情報 (Data1N')に置換え、当該更新情報を格納するセグメントに対応するフラグに"有効"、他のユーザデータセグメントに対応するフラグに"無効"を設定した前記Data Valid bit領域を付加した前記データフレーム情報の送信処理を実施する。

# [0189]

更に、記憶装置1-1では、前述と同様にデータ更新処理、並びに、ステータス送信処理等を実施し、一連のライトデータ要求処理を完了する。

# [0190]

また、自身がデータ更新処理を実施すると判断した記憶装置1-2においても、前記ディスク制御部14-2を介して、ディスク部11-2に格納されている更新対象のデータ(旧データ:Data20)に対するディスクリード処理を開始する

# [0191]

更に、前段の記憶装置 1-1 から前記インタフェース制御部 13-2を介して受信したデータ(更新情報: Data1N'、新データ: Data2N)の内、自身に対する新データ(Data2N)と上記旧データ(Data2O)とから、例えば、排他的論理和演算結果等による更新情報(Data2N')を前記更新情報生成部 16-2で生成する。

# [0192]

更に、前段の記憶装置 1-1から受信したデータ (Data1N'、Data2N)の内、自身に対する新データ (Data2N)を上記更新情報 (Data2N')に置換え、当該更新情報を格納するセグメントに対応するフラグを"有効"に設定した前記データフレーム情報の送信処理を実施する。

#### [0193]

更に、前述と同様にデータ更新処理、並びに、前段の装置から受信したステータス情報と自身のステータス情報とから、新たなステータス情報の生成送信処理を実施し、前記アクセス要求を削除することによって、一連のライトデータ要求処理を完了する。

#### [0194]

また、自身が冗長データ更新処理を実施すると判断した記憶装置1-Nにおいても、前記ディスク制御部14-Nを介して、ディスク部11-Nに格納されている更新対象の冗長データ(旧冗長データ:DataPO)に対するディスクリード処理を開始する。

#### [0195]

# [0196]

更に、記憶装置1-Nでは、上述の処理に係るステータス情報と上述のデータ 更新処理を実施した記憶装置1-1/2から受信したステータス情報とに基づく 新たなステータス情報を生成し、上位装置2に対して送信処理を実施した後、前 記アクセス要求を削除することによって、一連のライトデータ要求処理を完了す る。

#### [0197]

尚、上記冗長データの更新処理に当っては、前述と同様に、前記Data Valid b it領域の対応するフラグの設定値に基づき実施するものである。

# [0198]

次に、前記記憶装置サブシステム4を構成する前記記憶装置1における、上述のリードデータ要求処理とライトデータ要求処理とについて説明する。

#### [0199]

図32は、上位装置2からのリードデータ要求に対する、記憶装置1での処理フロー例を示す図である。

#### [0200]

記憶装置1は、前記協調制御情報29と、前記受信コマンド格納部26に格納 したアクセス要求情報とに基づき、該アクセス要求を自身が処理するか否か(データ送信要否)の判別処理を実施する(ステップ100)。

#### [0201]

自身が処理しないと判断した記憶装置1は、後述のアクセス要求削除(ステップ106)を実施し、前記リードデータ要求に掛かる処理を完了する。

# [0202]

自身が処理すると判断した記憶装置1は、前記ディスク制御部14を介してデ

ィスク部11から前記バッファ部12の前記送受信データ格納部27に対するディスクリード処理を開始し(ステップ101)、更に、前記協調制御情報29と、前記アクセス要求情報とに基づき、自身がリードデータの送信開始を許可されたか否か(リードデータ送信開始可否検出)の判別処理を実施する(ステップ102)。

# [0203]

自身がリードデータの送信の開始を許可された記憶装置1は、前記ユーザデータセグメントOに自身のリードデータを、他のユーザデータセグメントにはダミーデータを格納し、更に、前記ユーザデータセグメントOに対応するフラグに"有効"を、他のユーザデータセグメントに対応するフラグに"無効"を設定した前記データフレーム情報を生成し、後段の装置に対する送信処理を実施する(ステップ103)。

#### [0204]

ここで、上記自身がリードデータの送信の開始を許可された記憶装置1以外に、前記上位装置2からのアクセス要求を協調して処理する記憶装置が存在しない場合、当該記憶装置1は、上記フラグ情報(Data Valid bit領域)の設定/追加を実施することなく、リードデータのみから構成されるデータフレーム情報を生成し、上位装置2に対する送信処理を実施する。

#### [0205]

一方、自身がリードデータの送信の開始を禁止された記憶装置 1 は、前段の記憶装置からの前記リードデータフレームの受信を待ち(ステップ107)、該リードデータフレームの受信を契機として(ステップ108)、受信したリードデータフレームの更新処理(自身のリードデータを格納すべきユーザデータセグメントに自身のリードデータを格納し、更に、当該ユーザデータセグメントに対応するフラグに"有効"を設定)を行い、更新したリードデータフレームの送信処理を実施する(ステップ109)。

#### [0206]

ここで、自身がリードデータの送信の開始を禁止された記憶装置1で、且つ、 前記ユーザデータセグメントの最終セグメントに自身のリードデータを格納する 記憶装置1は、上記フラグ情報(Data Valid bit領域)を削除し、リードデータの みから構成されるデータフレーム情報を生成し、上位装置2に対する送信処理を 実施する。

#### [0207]

また、自身が処理すると判断した記憶装置1は、前記協調制御情報29と、前記受信コマンド格納部26に格納したアクセス要求情報とに基づき、該アクセス要求処理の完了報告送信開始を許可されたか否か(完了報告送信開始可否検出)の判別処理を実施する(ステップ104)。

#### [0208]

自身が完了報告の送信の開始を許可された記憶装置1は、上記リードデータ処理に係るステータス情報を生成し、後段の装置に対する送信処理を実施し(ステップ105)、更に、ステータス情報の送信処理後、前記アクセス要求を削除する(ステップ106)ことによって、一連のリードデータ要求処理を完了する。

# [0209]

一方、自身が完了報告の送信の開始を禁止された記憶装置1は、前段の記憶装置からの前記ステータス情報の受信を待ち(ステップ110)、該ステータス情報の受信を契機として(ステップ111)、受信したステータス情報の更新処理(自身のリードデータ処理結果の反映)を行い、更新したステータス情報の送信処理を実施(ステップ112)後、前記アクセス要求を削除する(ステップ106)ことによって、一連のリードデータ要求処理を完了する。

# [0210]

尚、上述の実施例において、前記ユーザデータセグメント〇に自身のリードデータを格納するか否かを前記リードデータ送信開始可否検出の条件例とし、更に、前記ユーザデータセグメント〇に自身のリードデータを格納する記憶装置において、前記フラグ情報(Data Valid bit領域)を付加した前記データフレーム情報を生成するものとして説明したが、これに限定するものではない。同様に、前記ユーザデータセグメントの最終セグメントに自身のリードデータを格納する記憶装置1において、上記フラグ情報(Data Valid bit領域)を削除し、リードデータから構成されるデータフレーム情報を生成するものとして説明したが、これに限定するものではなく、任意のアルゴリズムで上記記憶装置の決定を行うことが可

能である。

[0211]

図33は、上位装置2からのライトデータ要求に対する、記憶装置1での処理 フロー例を示す図である。

[0212]

記憶装置1は、前記協調制御情報29と、前記受信コマンド格納部26に格納 したアクセス要求情報とに基づき、該アクセス要求を自身が処理(データ更新) するか否か、更に、該アクセス要求に伴う冗長データ更新処理を実施するか否か の判別処理を実施する(ステップ200)。

[0213]

自身が処理しないと判断した記憶装置1は、後述のアクセス要求削除(ステップ209)を実施し、前記ライトデータ要求に掛かる処理を完了する。

[0214]

自身がデータ更新処理を実施すると判断した記憶装置1は、前記ディスク制御部14を介して、ディスク部11に格納されている更新対象のデータ(旧データ)に対するディスクリード処理を開始する(ステップ201)。

[0215]

更に、前段の装置からライトデータフレーム情報の受信を待ち(ステップ202) 、該ライトデータフレーム情報の受信を契機として(ステップ203)、該受信ライトデータフレーム情報を構成するライトデータ(新データ集合体)の内、自身が格納すべき新データと上記旧データとから、排他的論理和演算等による更新情報を前記更新情報生成部16で生成する(ステップ204)。

[0216]

更に、上記受信したライトデータフレーム情報を構成するライトデータ(新データ集合体)の内、自身に対する新データを上記更新情報に置換え、当該更新情報を格納するユーザデータセグメントに対応するフラグを"有効"に設定した前記ライトデータフレーム情報の送信処理を実施する(ステップ205)。

[0217]

ここで、上記受信したライトデータフレーム情報が、前記フラグ情報(Data Va

lid bit領域)を付加していない場合、記憶装置 1 は、自身の更新情報を格納する ユーザデータセグメントに対応するフラグに"有効"を、 他のユーザデータセ グメントに対応するフラグに"無効"を設定した上記フラグ情報を付加したライ トデータフレーム情報を生成し、当該ライトデータフレーム情報の送信処理を実 施する。

# [0218]

更に、上記自身が格納すべき新データを、前記ディスク制御部14を介してディスク部11に格納(ディスクライト)することによって、ライトデータ更新処理を実施する(ステップ206)。

# [0219]

また、自身が冗長データ更新処理を実施すると判断した記憶装置1は、前記ディスク制御部14を介して、ディスク部11に格納されている更新対象の冗長データ (旧冗長データ) に対するディスクリード処理を開始する(ステップ210)。

# [0220]

更に、前段の装置からライトデータフレーム情報の受信を待ち(ステップ211)、該ライトデータフレーム情報を構成する前記ユーザデータセグメントに対応する全ての前記フラグ情報(Data Valid bit領域)が"有効"に設定されていることの検出を契機として(ステップ212)、該ライトデータフレーム情報を構成する更新情報(集合体)と上記旧冗長データとから、排他的論理和演算等による新冗長データを前記更新情報生成部16で生成する(ステップ213)。なお、ここでは、条件として、全てのフラグ情報としたが、所定の条件を満たすフラグ情報としてもよい。該新冗長データを、前記ディスク制御部14を介してディスク部11に格納することによって、冗長データ更新処理を実現する(ステップ214)。

#### [0221]

ここで、上記ライトデータフレーム情報を構成する前記ユーザデータセグメントに対応する全ての前記フラグ情報が"有効"に設定されていない場合、受信したライトデータフレームを再送するものとする。

# [0222]

これによって、データ更新対象の記憶装置が、上記冗長データ更新対象記憶装

置の後段に位置する場合でも、上記データ更新対象の記憶装置による前記更新情報の生成/送信処理が実現可能となる。

[0223]

尚、当該処理によって、再度、上記ライトデータフレーム情報を受信した記憶装置は、該ライトデータフレーム情報を構成する前記フラグ情報に基づき、例えば、自身が格納すべきユーザデータセグメントに対応するフラグが"有効"に設定されていることを条件として、再送処理を実施する。

# [0224]

また、自身がデータ更新処理、或いは、冗長データ更新処理を実施すると判断 した記憶装置1は、前記協調制御情報29と、前記受信コマンド格納部26に格 納したアクセス要求情報とに基づき、該アクセス要求処理の完了報告送信開始を 許可されたか否か(完了報告送信開始可否検出)の判別処理を実施する(ステッ プ207)。

# [0225]

自身が完了報告の送信の開始を許可された記憶装置1は、上記ライトデータ処理に係るステータス情報を生成し、後段の装置に対する送信処理を実施し(ステップ208)、更に、ステータス情報の送信処理後、前記アクセス要求を削除する(ステップ209)ことによって、一連のライトデータ要求処理を完了する。

#### [0226]

一方、自身が完了報告の送信の開始を禁止された記憶装置 1 は、前段の記憶装置からの前記ステータス情報の受信を待ち(ステップ215)、該ステータス情報の受信を契機として(ステップ216)、受信したステータス情報の更新処理(自身のライトデータ処理結果の反映)を行い、更新したステータス情報の送信処理を実施(ステップ217)後、前記アクセス要求を削除する(ステップ209)ことによって、一連のライトデータ要求処理を完了する。

#### [0227]

尚、上述の実施例において、データ更新処理対象の全ての記憶装置でのデータ 更新処理実施後、冗長データの更新処理を行うこととしていることから、上記冗 長データ更新対象の記憶装置が最終的なステータス情報を生成/送信するものと しているが、これに限定するものではない。同様に最終的なステータス情報の生成方法についても、個々の記憶装置がステータス情報を更新する方法を例に説明したが、これに限定するものではなく、例えば、前記記憶装置サブシステム4を構成する特定の記憶装置が、上記ステータス情報の生成送信を管理することも可能である。

[0228]

[第五の実施形態] (縮退動作)

以下、本発明に係る第五の実施形態を、図34~17を用いて説明する。

[0229]

第五の実施形態は、第四の実施形態の記憶装置が、更に、協調して処理する他の記憶装置の動作状態情報を追加保持することによって、前記記憶装置サブシステムを構成する記憶装置に障害が発生した場合でも、上位装置から記憶装置サブシステムに対するアクセス要求処理を実現するものである。

[0230]

図34は、前述の実施形態の説明で用いた前記協調制御情報29の冗長構成管理情報を構成する情報として、RAIDレベル情報に"5"、データディスク台数/冗長データディスク台数情報に"3/1"が設定され、更に、動作モード情報と障害記憶装置識別情報(障害記憶装置ID)とを保持し、ID\_2の記憶装置障害による縮退モードが設定されている例である。

[0231]

尚、本実施形態における記憶装置は、前述の構成と同じであることから図を省略する。

[0232]

また、後述のデータ復元処理が不要な場合は、前述の実施形態と同一の制御で 実施可能であることから説明を省略する。

[0233]

以下、記憶装置サブシステム4を構成する記憶装置1-2おいて障害が発生した場合を例に、前記上位装置2から記憶装置サブシステム4に対するアクセス要求を、上記記憶装置1-2を除く他の記憶装置が協調して処理する動作を説明す

る。

# [0234]

(1) 障害記憶装置に対するリード処理(複数台の記憶装置でデータ復元処理実現)

図35は、障害状態にある記憶装置1-2に格納されたデータに対する上位装置2からのリードデータ要求を、上記記憶装置1-2以外の記憶装置で処理する場合のデータ転送処理例を示す図である。

# [0235]

前記受信コマンド格納部26に上記アクセス要求情報を格納した記憶装置1-2以外の記憶装置は、上記アクセス要求情報と前記協調制御情報29とに基づき、該アクセス要求を処理するに当り、障害状態にある記憶装置1-2に格納されたデータの復元処理が必要であることを検出し、更に、自身が該データ復元処理を実施するか否かを判別する。

# [0236]

障害状態にある記憶装置に格納されたデータの復元処理が必要と判断した記憶装置は、必要ならば、前記ディスク制御部14を介して、ディスク部11に格納されている上記データ復元処理に必要なデータ(図中、Data1, Data3, Data4)に対するディスクリード処理を開始する。

#### [0237]

尚、以下の説明では、前記アクセス要求情報と前記協調制御情報29とに基づき、最前段に位置する(上位装置からの情報を最も早く受信する)記憶装置が、上記データ復元処理に係るデータの送信を開始し、最後段に位置する(上位装置からの情報を最後に受信する)記憶装置が、上記データ復元処理を実施する場合を例に説明するが、これに限るものではない。

#### [0238]

自身が前記データ復元処理に係るデータ送信の開始を許可された記憶装置1-1では、例えば、前記ユーザデータセグメント0に自身のデータを格納し、更に、前記ユーザデータセグメント0に対応するフラグに"有効"を、他のユーザデータセグメントに対応するフラグに"無効"を設定した前記データフレーム情報

の送信処理を実施し、更に、該処理に係るステータス情報の生成送信後、前記ア クセス要求を削除することによって、一連のリードデータ要求処理を完了する。

# [0239]

また、自身が前記データ復元処理に係るデータ送信の開始を禁止された記憶装置1-3では、上記記憶装置1-1から受信した上記データフレーム情報に、自身のデータを格納したユーザデータセグメント1を追加し、更に、前記ユーザデータセグメント1に対応するフラグに"有効"を設定したデータフレーム情報の生成/送信処理を実施し、更に、該処理に係るステータス情報と前段の装置から受信したステータス情報とに基づく新たなステータス情報を生成送信後、前記アクセス要求を削除することによって、一連のリードデータ要求処理を完了する。

#### [0240]

更に、自身が前記データ復元処理を実施すると判断した記憶装置1-4では、上記記憶装置1-1/3から受信したデータ(Data1, Data3)と、自身が格納し上記データ復元処理に必要なデータ(Data4)とから、前記更新情報生成部16-4での排他的論理和演算等によって、前記障害状態にある記憶装置1-2に格納されたデータ(Data2)の復元処理を実施し、更に、復元したデータ(Data2)を用いて前記上位装置2に対してリードデータフレーム情報の送信処理を実施する。

#### [0241]

尚、上記データ復元処理を実施する最終段の記憶装置、即ち、上位装置に対する最終形のデータフレーム情報を生成する記憶装置においては、前記ユーザデータセグメントのデータが有効か否かを示すフラグ(Data Valid bit)領域を削除して、ユーザデータのみから構成されるペイロードとして上位装置に送信することが望ましい。

#### [0242]

また、上位装置2に対するステータス情報の送信処理としては、上記データ送信処理を実施する最終段の記憶装置、即ち、上位装置に対する最終形のデータフレーム情報を生成する記憶装置において、前段の装置から受信したステータス情報と自身のステータス情報とから新たなステータス情報を生成送信することによって、上位装置2に対するステータス情報の生成を実現している。

#### [0243]

また、上述の実施形態では、障害状態にある記憶装置 1 - 2 に格納されたデータのみに対する上位装置 2 からのリードデータ要求を、上記記憶装置 1 - 2 以外の記憶装置で処理する場合を例に説明したが、これに限定するものではなく、例えば、記憶装置 1 - 1 / 2 に格納されたデータに対するリードデータ要求の場合、上記記憶装置 1 - 4 において、前記記憶装置 1 - 1 から受信したデータ (Data1)と自身が復元したデータ (Data2)とを用いて、上位装置に対する最終形のデータフレーム情報を生成/送信することが可能である。

#### [0244]

(2) 障害記憶装置に対するライト処理(複数台の記憶装置で冗長データ更新処理実現)

図36は、障害状態にある記憶装置1-2に対する上位装置2からのライトデータ要求を、上記記憶装置1-2以外の記憶装置で処理する場合のデータ転送処理例を示す図である。

# [0245]

前記受信コマンド格納部26に上記アクセス要求情報を格納した記憶装置1-2以外の記憶装置は、上記アクセス要求情報と前記協調制御情報29とに基づき、データ更新処理を自身が実施するか否か、或いは、該アクセス要求に伴う冗長データ更新処理を自身が実施するか否かを判別する。

# [0246]

上記データ更新処理、或いは、冗長データ更新処理を実施しないと判断した記憶装置は、必要ならば、前記ディスク制御部14を介して、ディスク部11に格納されている上記冗長データ更新処理に必要なデータ(図中、Datal, Data3)に対するディスクリード処理を開始する。

#### [0247]

尚、以下の説明では、最前段に位置する(上位装置からの情報を最も早く受信する)記憶装置が、上記冗長データ更新処理に係るデータの送信を開始し、最後段に位置する(上位装置からの情報を最後に受信する)記憶装置が、上記データ復元処理を実施する場合を例に説明するが、これに限るものではない。

# [0248]

自身が前記冗長データ更新処理に係るデータ送信の開始を許可された記憶装置 1-1では、例えば、自身のデータ(Data1)を前記ユーザデータセグメント 0 に、上位装置 2 から受信した新データ(Data2)を前記ユーザデータセグメント 1 格納し、更に、前記ユーザデータセグメント 0 / 1 に対応するフラグに "有効"を、他のユーザデータセグメントに対応するフラグに "無効"を設定した前記データフレーム情報の送信処理を実施し、更に、該処理に係るステータス情報の生成送信後、前記アクセス要求を削除することによって、一連のライトデータ要求処理を完了する。

# [0249]

また、自身が前記冗長データ更新処理に係るデータ送信の開始を禁止された記憶装置1-3では、上記記憶装置1-1から受信した上記データフレーム情報に、自身のデータ(Data3)を格納したユーザデータセグメント2を追加し、更に、前記ユーザデータセグメント2に対応するフラグに"有効"を設定したデータフレーム情報の生成/送信処理を実施し、更に、該処理に係るステータス情報と前段の装置から受信したステータス情報とに基づく新たなステータス情報を生成送信後、前記アクセス要求を削除することによって、一連のライトデータ要求処理を完了する。

#### [0250]

更に、自身が前記冗長データ更新処理を実施すると判断した記憶装置 1-4 では、最終的に上記記憶装置 1-3 から受信したデータ(Data1, Data2, Data3)から、前記更新情報生成部 16-4 での排他的論理和演算等によって、新たな冗長データ(DataP)を生成し、更に、生成した冗長データ(DataP)を、前記ディスク制御部 14-4 を介してディスク部 11-4 に格納することによって、冗長データ更新処理を実現する。

#### [0251]

更に、記憶装置1-4では、上述の処理に係るステータス情報と前段の装置から受信したステータス情報とに基づく新たなステータス情報を生成し、上位装置 2に対して送信処理を実施した後、前記アクセス要求を削除することによって、 一連のライトデータ要求処理を完了する。

[0252]

尚、上記冗長データの更新処理に当っては、前記Data Valid bit領域の対応するフラグが"有効"に設定されているか否かを検出し、"有効"に設定されている場合についてのみ冗長データの更新処理を実施し、"無効"の設定が残っている場合は受信したデータフレーム情報を後段の装置に対して再送することによって、例えば、冗長データ更新を実施する記憶装置の後段にデータ更新処理対象の記憶装置が位置する場合でも、上記冗長データ更新処理を実現することが可能となる。

[0253]

また、上述の実施形態では、障害状態にある記憶装置1-2に格納されたデータのみに対する上位装置2からのライトデータ要求を、上記記憶装置1-2以外の記憶装置で処理する場合を例に説明したが、これに限定するものではなく、例えば、記憶装置1-1/2に格納されたデータに対するライトデータ要求の場合、上記記憶装置1-1/2に格納されたデータに対するライトデータ要求の場合、上記記憶装置1-1において、上述のディスクリード処理を実施することなく、上位装置2から受信した新データ(Data1)を、前記ディスク制御部14-1を介してディスク部11-1に格納することによって、データ更新処理を実現し、更に、上位装置2から受信した新データ(Data1, Data2)を前記ユーザデータセグメント0/1格納し、更に、前記ユーザデータセグメント0/1に対応するフラグに"有効"を、他のユーザデータセグメントに対応するフラグに"無効"を設定した前記データフレーム情報の送信処理を実施し、更に、該処理に係るステータス情報の生成送信後、前記アクセス要求を削除することによって、一連のライトデータ要求処理を完了することが可能である。

[0254]

更に、上記協調制御情報29においては、上位装置から設定可能であることが望ましく、更に、自身の判断によって、前記動作モード情報等を設定可能であることが望ましい。

[0255]

[第六の実施形態] (マルチパス制御)

以下、本発明に係る第六の実施形態を、図37、19を用いて説明する。

[0256]

第六の実施形態は、上述の実施形態の記憶装置が、更に、複数のインタフェース制御部を具備し、上位装置からのアクセス要求情報と、記憶装置サブシステムを構成する記憶装置間で転送されるユーザデータとの転送処理を、異なるインタフェース(伝送路)を用いて実現するものである。

[0257]

図37は、複数(N, N>1)台の記憶装置1から構成される記憶装置サブシステム 4と、上位装置2とから構成される情報処理システムの一例を示す図である。

[0258]

同図において、記憶装置サブシステム4を構成する個々の記憶装置1が、複数のインタフェース制御部A/B(13-a/b)を具備し、該インタフェース制御部A13-aを用いて、前述の実施形態と同様に、前記上位装置2と巡回型のインタフェース3-aを介して直接接続される。同時に、該インタフェース制御部B13-bを用いて、記憶装置サブシステム4を構成する個々の記憶装置1が、巡回型のインタフェース3-bを介して接続されている。

[0259]

尚、上記情報処理システムの構成例として、記憶装置サブシステム4を構成する個々の記憶装置1のみを、前記インタフェース制御部B13-bを用いて、巡回型のインタフェース3-bを介して接続する構成としているが、後述の通り、これに限定するものではない。

[0260]

以下、記憶装置サブシステム4を構成する記憶装置1-2おいて障害が発生した状態で、上位装置2から上記障害状態にある記憶装置1-2に格納されたデータに対するリードデータ要求を、上記記憶装置1-2を除く他の記憶装置が協調して処理する場合を例に動作を説明する。

[0261]

図38は、障害状態にある記憶装置1-2に格納されたデータに対する上位装

置2からのリードデータ要求を、上記記憶装置1-2以外の記憶装置で処理する 場合のデータ転送処理例を示す図である。

# [0262]

前記受信コマンド格納部26に、インタフェース制御部A13-aを介して、 上記アクセス要求情報を格納した記憶装置1-2以外の記憶装置は、前述の実施 形態と同様に、上記アクセス要求情報と前記協調制御情報29とに基づき、該ア クセス要求を処理するに当り、障害状態にある記憶装置1-2に格納されたデー タの復元処理が必要であることを検出し、更に、自身が該データ復元処理を実施 するか否かを判別する。

# [0263]

障害状態にある記憶装置に格納されたデータの復元処理が必要と判断した記憶装置は、必要ならば、前記ディスク制御部14を介して、ディスク部11に格納されている上記データ復元処理に必要なデータ(図中、Data1, Data3, Data4)に対するディスクリード処理を開始する。

# [0264]

自身が前記データ復元処理に係るデータ送信の開始を許可された記憶装置 1 ー 1 では、例えば、前記ユーザデータセグメント 0 に自身のデータ (Data1)を格納し、更に、前記ユーザデータセグメント 0 に対応するフラグに "有効"を、他のユーザデータセグメントに対応するフラグに "無効"を設定した前記データフレーム情報の送信処理を、上記アクセス要求情報を受信したインタフェース制御部Aとは異なるインタフェース制御部Bを用いて実施し、更に、該処理に係るステータス情報の生成送信後、前記アクセス要求を削除することによって、一連のリードデータ要求処理を完了する。

#### [0265]

また、自身が前記データ復元処理に係るデータ送信の開始を禁止された記憶装置1-3では、上記記憶装置1-1から受信した上記データフレーム情報に、自身のデータを格納したユーザデータセグメント1を追加し、更に、前記ユーザデータセグメント1に対応するフラグに"有効"を設定したデータフレーム情報の生成/送信処理、更に、該処理に係るステータス情報と前段の装置から受信した

ステータス情報とに基づく新たなステータス情報を生成送信処理を、上記記憶装置1-1と同様に、上記アクセス要求情報を受信したインタフェース制御部Aとは異なるインタフェース制御部Bを用いて実施した後、前記アクセス要求を削除することによって、一連のリードデータ要求処理を完了する。

# [0266]

更に、自身が前記データ復元処理を実施すると判断した記憶装置1-4では、上記記憶装置1-1/3から、前記インタフェース制御部B13-4bを介して受信したデータ(Data1, Data3)と、自身が格納し上記データ復元処理に必要なデータ(Data4)とから、前記更新情報生成部16-4での排他的論理和演算等によって、前記障害状態にある記憶装置1-2に格納されたデータ(Data2)の復元処理を実施し、更に、復元したデータ(Data2)を、前記インタフェース制御部A13-4a用いて前記上位装置2に対するリードデータフレーム情報の送信処理を実施するものである。

# [0267]

尚、詳細な説明は省略するが、ライトデータ処理においても同様に、上位装置からのアクセス要求情報を受信したインタフェースと異なるインタフェースを用いて、記憶装置サブシステムを構成する記憶装置間で協調したデータ転送処理を実現することが可能である。

# [0268]

また、上述の説明において、上位装置からのアクセス要求情報を受信したインタフェースと異なるインタフェースを用いて、記憶装置サブシステムを構成する記憶装置間で協調したデータ転送処理を実施する場合を例に説明しているが、これに限定するものではなく。例えば、フレーム送信時のインターフェースの稼動状況に基づき、前記協調処理を実施する記憶装置間でのデータ転送処理を行うインタフェースを選択することも可能であり、該データ転送処理を実施するインタフェース上に上位装置2が接続されていても何ら問題は無い。

#### [0269]

以上説明した各実施形態には、以下の効果がある。

本発明の第一の実施形態によれば、複数の記憶装置から構成される記憶装置シ

ステムにおいて、該記憶装置システムを構成する個々の記憶装置が、上位装置から記憶装置システムに対するアクセス要求を、前記複数の記憶装置で共有する手段と、上記共有したアクセス要求について、自身が処理すべきか否かを判別する手段と、更に、上位装置から記憶装置システムに送信されるライトデータを、少なくとも、処理すべきと判断した記憶装置に転送する手段とを具備することによって、個々の記憶装置を制御する制御装置が不要で、また、記憶装置の利用効率の向上が期待される記憶装置システムが実現可能となる。

#### [0270]

本発明の第二の実施形態によれば、複数の記憶装置から構成される記憶装置システムにおいて、該記憶装置システムを構成する少なくとも一台の記憶装置が、上位装置から記憶装置システムに対するアクセス要求を受領し、更に、当該記憶装置において、上記アクセス要求を処理すべき記憶装置の判別を実施し、必要な場合、前記上位装置から記憶装置システムに対するアクセス要求を、処理すべき記憶装置に対して転送する手段を具備することによって、個々の記憶装置を制御する制御装置が不要で、また、記憶装置の利用効率の向上が期待される記憶装置システムが実現可能となる。

#### [0271]

本発明の第三の実施形態によれば、複数の記憶装置から構成される記憶装置システムにおいて、記憶装置システムを構成する個々の記憶装置が、少なくとも上位装置から記憶装置システムに対するライトデータ要求を共有する手段と、上記共有したライトデータ要求について、対を成す複数の記憶装置間でライトデータの転送処理と、当該ライトデータ要求に対するステータス情報の送信処理とを同期して実施する手段とを具備することによって、個々の記憶装置を制御する制御装置が不要でインタフェース負荷を軽減する記憶装置システムが実現可能となる

# [0272]

# 【発明の効果】

本発明により、複数の記憶装置から構成されるRAID1を含む記憶装置システムにおいて、上位装置からのアクセス要求を、記憶装置システムを構成する複数の

記憶装置間で協調して処理ことが可能となる。

#### 【図面の簡単な説明】

- 【図1】本発明の情報処理システムの一構成例を示す図
- 【図2】本発明の第一実施形態に係る記憶装置の一構成例を示す図
- 【図3】本発明の第一実施形態に係るリード処理フローの一例を示す図
- 【図4】本発明の第一実施形態に係るリード処理における情報転送の一例を示す 図
  - 【図5】本発明の第一実施形態に係るライト処理フローの一例を示す図
- 【図 6】本発明の第一実施形態に係るライト処理における情報転送の一例を示す 図
  - 【図7】本発明の第一実施形態に係る未更新領域管理情報の一構成例を示す図
- 【図8】本発明の第一実施形態に係る未更新領域の更新処理における情報転送の 一例を示す図
- 【図9】本発明の第二実施形態に係る記憶装置の一構成例を示す図
- 【図10】本発明の第二実施形態に係るリード処理フローの一例を示す図
- 【図11】本発明の第二実施形態に係るリード処理における情報転送の一例を示す図
- 【図12】本発明の第二実施形熊に係るライト処理フローの一例を示す図
- 【図13】本発明の第二実施形態に係る未更新領域の更新処理における情報転送 の一例を示す図
  - 【図14】本発明の第三実施形態に係るライト処理フローの一例を示す図
- 【図15】本発明の第三実施形態に係るライト処理における情報転送の一例を示す図
- 【図16】本発明の協調制御情報の一構成例を示す図
- 【図17】アクセス要求情報の一構成例を示す図
- 【図18】フレームヘッダ情報の一構成例を示す図
- 【図19】本発明のライト処理管理情報の一構成例を示す図
- 【図20】本発明の情報処理システムの一構成例を示す図
- 【図21】本発明の第四実施形態に係る記憶装置の一構成例を示す図

- 【図22】本発明の第四実施形態に係る協調制御情報の構成及び設定例を示す図
- 【図23】本発明で使用されるフレーム情報の一構成例を示す図
- 【図24】本発明で使用されるフレーム情報を構成するフレーム情報の一構成例 を示す図
- 【図25】本発明で使用されるフレーム情報を構成するアクセス要求情報の一構 成例を示す図
  - 【図26】本発明におけるアクセス要求情報の転送処理フローの一例を示す図
- 【図27】本発明の第四実施形態に係るリードデータ転送処理(単一)の一例を 示す図
- 【図28】本発明の第四実施形態に係るリードデータ転送処理(複数)の一例を 示す図
  - 【図29】本発明におけるデータフレーム情報の一構成例を示す図
- 【図30】本発明の第四実施形態に係るライトデータ転送処理(単一)の一例を 示す図
- 【図31】本発明の第四実施形態に係るライトデータ転送処理(複数)の一例を 示す図
- 【図32】本発明の第四実施形態に係るリード処理フローの一例を示す図
- 【図33】本発明の第四実施形態に係るライト処理フローの一例を示す図
- 【図34】本発明の第五実施形態に係る協調制御情報の構成及び設定例を示す図
- 【図35】本発明の第五実施形態に係るリードデータ転送処理(縮退)の一例を 示す図
- 【図36】本発明の第五実施形態に係るライトデータ転送処理(縮退)の一例を 示す図
  - 【図37】本発明の第六実施形態に係る情報処理システムの一構成例を示す図
- 【図38】本発明の第六実施形態に係るリードデータ転送処理(縮退)の一例を 示す図

#### 【符号の説明】


1 · · · 記憶装置、2 · · · 上位装置、3 · · · インタフェース (SAN: Storage Area Network)、4 · · · 記憶装置システム、10 · · · メイン制御部、11

# 特2001-344010


・・・ディスク部(記憶媒体)、12・・・バッファ部、13・・・インタフェース制御部、14・・・ディスク制御部、15・・・バッファ制御部、20・・・受信部、21・・・送信部、22・・・受信フレーム処理部、23・・・送信フレーム生成部、24・・・再送判定部、25・・・出力選択部、26・・・受信コマンド格納部、27・・・送受信データ格納部、28・・・協調制御情報、29・・・コマンド転送制御部、30・・・未更新領域管理情報

【書類名】 図面

# 【図1】




【図2】




【図3】






【図4】




【図5】





【図6】




【図7】

図 7

			$\sim$	
#	未更新開始アドレス	未更新サイズ	更新情報	
0				
1				
2				
•				
N				

# 【図8】

図 8



【図9】








図10








【図12】


図12






【図13】

図13




### 【図14】

図 1 4



【図15】



# 【図16】

図16

協調制	御情報項目	記憶装置#1設定例	記憶装置#2設定例
記憶装	置システムID (共有ID)	10_0	ID_0
記憶装	置ID (固有ID)	ID_1	10_2
協調装	置ID (協調記憶装置固有ID)	10_2	10_1
協調処	理(コマンド転送)モード	コマンド再送	コマンド受領
領域	協調処理領域	0 - (H-1)	0 - (N-1)
管理	アクティブ領域開始アドレス	0	N/2
情報	アクティブ領域サイズ	N/2	N/2

# 【図17】

図17

Bit Byte	7	. 6	5	4	3	2	1	0	
0 - 7		FCP_LUN							
8		Command Reference Number							
9		Reserved Task Attribute							
10	<b>X</b>		T	ask Manag	ement Fla	gs			
11			Res	erved			Rd Data	Wr Data	
12		Operation Code							
13	Logic	al Unit I	lumbe r			Flag			
14 - 17			L	ogical Bl	ock Addre	\$\$			
18				Rese	rved				
19 - 20				Transfe	r Length				
21	Control								
22 - 27		Reserved							
28 - 31			,	FC	P_DL				

## 【図18】

図18


Byte Word	3	2	1	0				
0	R_CTL	D_ID						
1	CS_CTL		S_ID					
2	TYPE		F_CTL					
3	SEQ_ID	SEQ_ID SEQ_CNT						
4	OX	_10	RX_	_ID				
5	Parameter							

## 【図19】


図19

#	Host ID (S_ID)	OX_ID	RX_ID
0	10_3	0X_00	RX_00
1	ID_3	0X_01	RX_02
2	ID_4	0X_01	RX_04
•	-	-	-
N	-	_	-

【図20】



【図21】



## 【図22】

図22

協調制	御情報項目	記憶装置#1	記憶装置#2	記憶装置#N	
記憶装	置サブシステムID(共有ID)	10_0	<b>←</b>	-	
記憶装	<b>畳ID (固有ID)</b>	ID_1	ID_2	1 D_N	
ポジションマップ		1	2	. N	
コマン	ド転送モード	受信&再送	受信&再送	受信のみ	
	RAIDレベル	5	<b>←</b>	-	
冗長 構成	データディスク台数	N — 1	<b>←</b>	<b>←</b>	
管理 情報 冗長データディスク台数		1	<b>←</b>	<b>←</b>	
	冗長データ管理サイズ	6 4 (kB)	<b>←</b>	<b>←</b>	

## 【図23】

図23

	SOF	Header	Pay I oad	CRC	EOF	
- 1	001		1 47 1 444	0	COI	

# 【図24】

図24

Byte Word	3	2	1	0			
0	R_CTL	D_1D					
1	CS_CTL	. S_ID					
2	TYPE	F_CTL					
3	SEQ_ID	SEQ_ID	SEQ	_CNT			
4	OX_	ID	RX_	_1D			
5	Parameter						


### 【図25】

図25

Bit Byte	7	6	5	4	3	2	1	0		
0 - 7		FCP_LUN								
8		Command Reference Number								
9		Reserved Task Attribute								
10		Task Management Flags								
11		_	Res	erved			Rd Data	Wr Data		
12			٠	0perat	ion Code					
13	Logic	al Unit I	lumber			Flag				
14 - 17			L	ogical Bl	ock Addre	\$ \$				
18				Res	erved					
19 - 20				Transfe	r Length					
21	Control									
22 - 27		Reserved								
28 - 31				FCI	P_DL					


【図26】

図26




【図27】

図27



【図28】




【図29】

図29

Bit Byte	7	6	5	4	3	2	1	0	
0 - x		Data Valid bit							
-			User (	Read/Write	e) Data Se	egment O			
-			•		:	·			
-			User (I	Read/Write	e) Data Se	egment n			

【図30】




【図31】

図31 上位装置 Data1N Data2N 12,1 12,2 Data2N' 16-1 16,2 Data10 Data20 DataP0


【図32】





【図33】

図33




# 【図34】

図34

協調制	御情報項目	記憶装置#1	記憶装置#2	記憶装置#N
記憶器	置サブシステムID(共有ID)	1D_0	<b>←</b>	<b>←</b>
記憶姿	<b>置ID(固有ID)</b>	ID_1	ID_2	ID_H
ポジシ	ョンマップ	1	2	N
コマン	ド転送モード	受信&再送	受信&再送	受信のみ
	RAIDレベル	5	<b>←</b>	<b>←</b>
	データディスク台数	3	<b>-</b>	<i>i</i> ←
冗長 構成	冗長データディスク台数	1	-	-
管理 情報	冗長データ管理サイズ	6 4 (kB)	. ←	<b>←</b>
11.5 1.	動作モード(正常/縮退)	縮退	-	<b>←</b>
	障害記憶装置ID	ID_2	<b>←</b>	4-

【図35】




【図36】


図36 上位装置 Data2 Data2 障害 Data3 Datal Data2 Data3

【図37】

図37



【図38】



### 【書類名】 要約書

#### 【要約】

### 【課題】

複数の記憶装置から構成されるRAID1の記憶装置システムにおいて、上位装置からのアクセス要求を、該記憶装置システムを構成する複数の記憶装置間で協調して処理する制御方式を提供する。

#### 【解決手段】

RAID1の記憶装置システムを構成する個々の記憶装置が、上位装置からのアクセス要求を共有する手段と、上記共有したアクセス要求について、自身が処理すべきか否かを判別する手段と、更に、上位装置から記憶装置システムに送信されるライトデータを、少なくとも、処理すべき記憶装置に転送する手段とを具備する。

### 【選択図】 図2

### 認定・付加情報

特許出願の番号

特願2001-344010

受付番号

50101654669

書類名

特許願

担当官

第七担当上席

0096

作成日

平成13年11月14日

<認定情報・付加情報>

【提出日】

平成13年11月 9日

### 出願人履歴情報

識別番号

[000005108]

1. 変更年月日

1990年 8月31日

[変更理由]

新規登録

住 所

東京都千代田区神田駿河台4丁目6番地

氏 名

株式会社日立製作所